



Centro de Investigación en Matemáticas, A.C.

CIMAT

**Clasificación de emociones fusionando
características de análisis de respuesta
fisiológica y análisis automatizado de
conducta en video juegos.**

T E S I S

Que para obtener el grado de

Maestría en Ingeniería de Software

Presenta

Luis Salvador López Hernández

Director de Tesis:

Dr. Carlos Alberto Lara Álvarez

Co-Director de Tesis:

Dr. Hugo Arnoldo Mitre Hernández

ZACATECAS, ZAC. OCTUBRE DE 2016

Resumen

La computación afectiva es un tema de investigación que ha crecido en los últimos años. Los sistemas capaces de entender los estados afectivos son de utilidad para mejorar la experiencia de usuario, incrementar la inmersión y el aprendizaje, especialmente en los videojuegos y los software educativos. Las investigaciones en el reconocimiento de emociones se han enfocado en el análisis de la respuesta fisiológica o la conducta. El problema de los métodos que usan señales fisiológicas es que dependen de sistemas de sensores caros; por otro lado, las investigaciones de la conducta utilizan métodos libres de sensores, pero tienen poca precisión. Este trabajo propone la fusión de características de ambos métodos; esto permite el uso de dispositivos comerciales para la adquisición de datos de señales fisiológicas y complementa los datos con características de la conducta. Se realizó un experimento usando un videojuego, un dispositivo de seguimiento de movimiento y la pulsera e4 para la obtención de datos, luego se utilizó el método propuesto para clasificar emociones. Los resultados muestran un aumento en la precisión de el reconocimiento de emociones fusionando datos de las señales fisiológicas y datos de la conducta, comparado a solo utilizar las señales fisiológicas. Esto demuestra que el método propuesto ayuda a mejorar la detección de estados afectivos.

Palabras clave: Clasificación de emociones, señales fisiológicas, análisis de conducta, videojuegos.

Abstract

Affective computing is a research topic that has grown in recent years. Systems able to understand the affective states are useful to improve the user experience and increase engagement and learning, especially in video games and educational software. Researches in emotion recognition have focused on the analysis of the physiological response or behavior. Physiological signals approaches rely on expensive sensors systems; on the other hand, behavior investigations use sensors free methods, but they have low accuracy. This paper proposes merging features of both methods; this allows the use of commercial devices for physiological data acquisition and complements data with behavioral characteristics. Using a video game and the e4 wristband, data was gathered and used with the proposed methodology to classify emotions. The results show an increase in the accuracy of emotion recognition fusing physiological and user behavior data, compared to results using only physiological signals. This shows that the proposed method helps improve detection of affective states.

Keywords: Emotion recognition, physiological signals, behavior analysis, video games.

TABLA DE CONTENIDO

Resumen	III
Abstract	IV
Lista de Figuras	VIII
Lista de Tablas	VIII
1. Introducción	1
1.1. Clasificación de emociones	3
1.2. Ventajas y desventajas de los métodos de medición de emociones.	4
1.3. Emociones	5
1.4. Emociones, aprendizaje y video juegos	7
1.5. Motivación.....	7
1.6. Resumen de la propuesta	8
1.7. Objetivos.....	9
1.8. Hipótesis	9
1.9. Alcances y limitaciones.....	10
1.10. Estructura de la tesis	10
2. Marco teórico	11
2.1. Modelos de clasificación de emociones	11
2.2. Clasificación de emociones por señales fisiológicas.....	12
2.2.1. Actividad electro dérmica.	13
2.2.2. Ritmo cardíaco.	14
2.2.3. Temperatura de la piel	15
2.3. Clasificación de emociones por análisis automatizado de conducta.....	15
2.4. Resumen	16
3. Trabajos relacionados.....	18

3.1.	Trabajos relacionados al análisis de respuesta fisiológica.....	18
3.2.	Trabajos relacionados al análisis automatizado de conducta.	24
3.3.	Comparación con la propuesta.....	26
4.	Propuesta.....	28
4.1.	Señales fisiológicas	28
4.2.	Características.....	28
4.2.1.	Características de análisis de respuesta fisiológica.....	28
4.2.2.	Características de la conducta.....	30
4.2.3.	Característica de salida.....	31
4.3.	Clasificador.....	31
4.3.1.	SVM.....	32
4.3.2.	QDA.....	33
4.4.	Resumen de la propuesta	34
5.	Experimentación	35
5.1.	Diseño del experimento.....	35
5.2.	Participantes.....	35
5.3.	Videojuego.....	35
5.4.	Procedimiento.....	37
5.5.	Métricas	38
5.6.	Resultados.....	38
6.	Conclusión y Trabajos futuros	43
6.1.	Conclusión.....	43
6.2.	Trabajos futuros.....	44
	Bibliografía.....	45
	Anexos.....	51

Anexo A. Componentes principales para el análisis de las señales.....	51
-----------------------------------------------------------------------	----

Lista de Figuras

Figura 1: Imágenes de evaluación del SAM.....	2
Figura 2: Pulsera empática e4.....	4
Figura 3: Diagrama del método de clasificación de emociones.	8
Figura 4: Representación gráfica del modelo circumplejo afectivo.	12
Figura 5: Modelo del flujo (Csikszentmihalyi 2014).	31
Figura 6: Juego Dizzy Route.	37
Figura 7: Valencia en cada dificultad.....	40
Figura 8: Activación por dificultad.....	40
Figura 9: Proceso de análisis de las señales.	51

Lista de Tablas

Tabla 1: Dispositivos para la lectura de señales del sistema nervioso autónomo (SAN).....	3
Tabla 2: Trabajos de clasificación de emociones por análisis de respuesta fisiológica (Parte 1).....	18
Tabla 3: Trabajos de clasificación de emociones por análisis de respuesta fisiológica (Parte 2).....	19
Tabla 4: Trabajos de clasificación de emociones por análisis de respuesta fisiológica (Parte 3).....	20
Tabla 5: Trabajos de clasificación de emociones por análisis de respuesta fisiológica (Parte 4).....	21
Tabla 6: Trabajos de clasificación de emociones por análisis de respuesta fisiológica (Parte 5).....	22
Tabla 7: Acrónimos (Parte 1).....	22
Tabla 8: Acrónimos (Parte 2).....	23
Tabla 9: Propuesta del método de clasificación de emociones.....	34
Tabla 10: Relación entre vehículo y dificultad del juego.	36
Tabla 11: Comparación de valencia entre dificultades.....	39

Tabla 12: Comparación de activación entre dificultades.....	39
Tabla 13: Resultados de clasificación del experimento.....	41

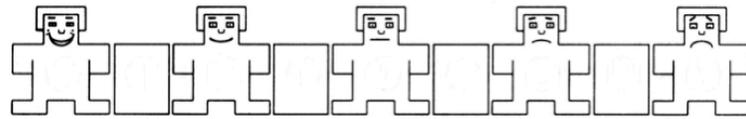
1.Introducción

La computación afectiva es un de tema de investigación ha crecido en los últimos años. La *computación afectiva* es aquella que se relaciona, surge de, o deliberadamente influencia la emoción u otro fenómeno afectivo (Picard 1995). Existen tres tipos de aplicaciones de computación afectiva: sistemas que detectan las emociones del usuario, sistemas que expresan lo que el humano percibe como una emoción, y sistemas que pueden “sentir una emoción”. Los investigadores del área interacción humano – computadora (HCI, del inglés: *Human – Computer Interaction*) han tomado interés en este tema debido a que la computación afectiva crea la posibilidad de desarrollar sistemas capaces de entender los estados afectivos de las personas, facilitando la comunicación entre humanos y computadoras (Calvo and D’Mello 2010); por lo tanto, la investigación en la computación afectiva es un área multidisciplinaria que apunta a explorar las experiencias afectivas con tecnología combinando ingeniería y tecnología computacional con varios dominios de investigación, como la psicología, la ciencia cognitiva, la neurociencia, la sociología, la educación, la psicofisiológica (Picard 1995).

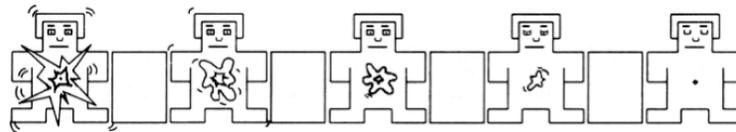
En los sistemas de computación afectiva necesitan identificar y medir las emociones. Según (Öhman 1987) existen tres tipos de métodos para medir emociones: auto-reporte, análisis de conducta y análisis de las respuestas fisiológicas.

Métodos de auto-reporte. Es un método subjetivo que depende del punto de vista de la persona. En la clasificación de emociones uno de los métodos de reporte usados es el maniquí de auto-evaluación(SAM, del inglés: *Self-assessment manikin*), este consiste en una serie de imágenes con las cuales la persona se puede identificar y valorar su estado emocional en valencia y activación usando una escala de 1 a n, donde $n = \{5,7,9\}$ (Bradley and Lang 1994). La Figura 1 muestra las imágenes de evaluación que utiliza el SAM, la figura 1a

son muñecos que van de alegre a triste (Valencia) y la figura 1b son de activo a calmado(Activación).



(a)



(b)

Figura 1: *Imágenes de evaluación del SAM*, (a) representa la escala de valencia de feliz a triste, (b) representa la escala de activación de activo a calmado

Análisis de conducta. Para el análisis de conducta se pueden observar dos tipos de métodos, el análisis por expertos y el análisis automático. El análisis de conducta por expertos es un método subjetivo que depende de la evaluación por parte de una serie de expertos que analizan el comportamiento de la persona. Por otro lado, el método de análisis de conducta automatizado es un método objetivo en el cual se usan datos de las acciones sujeto de prueba para encontrar un patrón y entender la conducta de esa persona. (Baker et al. 2012) muestran un ejemplo, donde se hace la detección de ciertas emociones en el uso de un software educativo llamado *Cognitive Tutor Algebra*. Baker et al. sugieren el uso de diferentes características, como: el mínimo y máximo de acciones incorrectas, el número de solicitudes de ayuda, el tiempo de respuesta entre acciones, la probabilidad de aprendizaje momento a momento, la probabilidad de adivinar, entre otros factores.

Análisis de respuesta fisiológica. Es una de las principales técnicas para la detección de emociones, se utilizan sensores que monitorean datos corporales como: el ritmo cardiaco (HR, del inglés: *Heart rate*), la actividad electro-dérmica (EDA, del inglés: *Electro dermal Activity*), la electroencefalografía (EEG), las

medidas de músculos faciales o electromiografía (EMG). Debido a que los datos fisiológicos son independientes del punto de vista de la persona, este método se considera un “método objetivo”.

1.1. Clasificación de emociones

Existe un esfuerzo considerable en la detección de emociones utilizando métodos de análisis de respuesta fisiológica. Estas investigaciones están divididas en dos enfoques, el análisis del sistema nervioso central (SNC) y el análisis del sistema autónomo nervioso (SAN). Las señales fisiológicas producidas por el SNC se pueden medir mediante el uso del electroencefalograma (EEG); por otro lado, las señales producidas por el SAN se refiere a la actividad del ritmo cardiaco (HR, del inglés: *Heart rate*), la actividad electro-dérmica (EDA, del inglés: *Electro dermal Activity*), la temperatura de la piel (SKT, del inglés: *Skin temperature*), la actividad de los músculos faciales, medida por medio de la electromiografía (EMG) y la respiración (RESP) (Park et al. 2013).

La mayoría de las investigaciones enfocadas en este tipo de clasificación sólo han sido probadas en laboratorios (Arroyo et al. 2009). Esto se debe a que utilizan sensores de alta precisión que sólo pueden ser usados en ambientes controlados, mientras que no se ha investigado lo suficiente haciendo uso de dispositivos comerciales como las pulseras de seguimiento de la condición física.

En la Tabla 1 se muestra una lista de los dispositivos para la lectura de señales del SAN encontrados en la literatura, así como las señales que mide, y la frecuencia utilizada.

Tabla 1: *Dispositivos para la lectura de señales del sistema nervioso autónomo (SAN).*

Trabajos relacionados	Dispositivo	Señales	Frecuencia (Velocidad máxima de muestreo)
(Friedrichs et al. 2015)	Olimex Shield-EKC-EMG	ECG,EMG	250hz.
(E.-H. Jang, Park, Park, Kim, & Sohn, 2015; E. Jang et al., 2013)	MP150	ECG, EMG, BVP, SKT, RESP	4000hz.
(Valenza et al. 2014)	ECG100C	ECG	250hz.

(Park et al. 2013)	TSD200D + PPG100C	BVP	200hz.
(Park et al. 2013)	SKT100C	SKT	200hz.
(Li & Chen, 2006; Selvaraj, Murugappan, Wan, & Yaacob, 2013)	Power Lab data Acquisition System	ECG, EMG, BVP, SKT, RESP	2000hz.
(Nogueira, Rodrigues, and Oliveira 2013)	Nexus-10	ECG, EMG, BVP, SKT, RESP	128hz. (SKT, RESP;BVP) 8192hz. (EEG,EMG,ECG)
(Yannakakis and Hallam 2007)	ProComp	ECG, EMG, BVP, SKT, RESP	256hz.
Este trabajo	Empática E4	BVP, EDA, SKT	64hz. (BVP) 4hz. (EDA, SKT)

Uno de los objetivos de este trabajo es el uso de un dispositivo de medición de señales fisiológicas de bajo costo, buscando comparar el resultado obtenido del método propuesto y el uso de un dispositivo comercial, con aquellos de los trabajos que usan sensores de alta precisión. Para este objetivo se considero la pulsera empática e4, esta permite tomar mediciones del EDA, SKT y BVP, de este último puede calcular los valores del HR. La capacidad de esta pulsera es inferior a los sensores utilizados en laboratorios, pero permite su aplicación en entornos no controlados.



Figura 2: Pulsera empática e4, con sensor fotopleletismografo, sensor para actividad electro-dérmica, termómetro infrarojo y acelerometro de 3 ejes.

1.2. Ventajas y desventajas de los métodos de medición de emociones.

Cada uno de estos métodos tiene su utilidad; sin embargo, también sus deficiencias. Los métodos subjetivos, como el auto-reporte y el análisis de

conducta por expertos, interrumpen el proceso natural afectivo, y están limitados en términos de aplicabilidad a gran escala (Arroyo et al. 2009).

Los métodos objetivos, como el análisis automatizado de conducta y el análisis de respuesta fisiológica, tienen el beneficio de poder realizarse en tiempo real; sin embargo, también tienen sus problemas. Los métodos de análisis de conducta automático tienden a tener una baja precisión, en la mayoría de los casos siendo solo un poco mejor que lanzar una moneda para adivinar. El análisis de respuesta fisiológica es poco útil para entornos fuera de laboratorios, ya que se requieren sensores que dificultan el movimiento de la persona, son de alto costo, y en algunos casos requieren expertos en el uso de estos sensores (Arroyo et al. 2009; McMahan, Parberry, and Parsons 2015). Estos métodos tienen una alta precisión debido al gran número de muestras que obtienen estos sensores.

Esta tesis busca un método de clasificación de emociones que fusione características obtenidas de datos fisiológicos y del análisis automatizado de conducta que permita incrementar la precisión de la detección, respecto de los métodos que solo usan características obtenidas de datos fisiológicos o aquellos que sólo usan análisis de conducta.

1.3. Emociones

Las emociones pueden ser definidas como un estado mental que ocurre espontáneamente sin ningún esfuerzo consciente y es acompañado por cambios fisiológicos (Selvaraj et al., 2013). Son producidas sistemáticamente por el proceso cognitivo, sentimientos subjetivos, activación fisiológica, tendencias motivacionales, y reacciones de comportamiento. Se cree que las emociones interactúan con la inteligencia matemática, verbal y perceptiva asociada con el cerebro humano (Selvaraj et al., 2013). En el campo de la educación los estados emocionales son importantes debido a que juegan un rol esencial en la toma de decisiones, la percepción y el aprendizaje (Ben Ammar et al. 2010).

Varios investigadores han planteado un conjunto de estados cognitivo-afectivos que influyen la cognición y el aprendizaje profundo. Estos incluyen

aburrimiento, confusión, deleite, inmersión, frustración y sorpresa (Baker et al. 2010). De acuerdo a sus teorías, los estudiantes están típicamente en un estado de inmersión cuando persiguen un objetivo de aprendizaje, y en estado de aburrimiento cuando abandonan el objetivo. Cuando el estudiante detecta información nueva o discrepante su atención cambia a esta información, el sistema nervioso autónomo incrementa la activación, y el estudiante experimenta una variedad de estados dependiendo del contexto, y de si el objetivo aun se puede conseguir. En el caso de algo extremadamente novedoso, los eventos crean sorpresa. Cuando hay una retroalimentación positiva de una acción o un logro de un objetivo difícil, la emoción es positiva, como el caso del deleite. En contraste, confusión y frustración ocurren cuando la discrepancia o novedad desencadenan un punto muerto que impide llegar al objetivo de aprendizaje (S. D'Mello and Graesser 2011).

Estas emociones que se experimentan en el aprendizaje dan información de la efectividad del material que se muestra. Según el estudio de (Leutner 2014) el proceso cognitivo y los resultados del aprendizaje pueden ser influenciados por factores como el interés situacional, emociones positivas o confusión. (Pekrun et al. 2011) reafirman esta investigación sugiriendo que las emociones positivas incrementan la motivación intrínseca al estimular la curiosidad de explorar nuevo conocimiento, lo cual lleva a un mejor desempeño en el aprendizaje.

Otro aspecto importante que se ha mostrado es la utilidad de las emociones de mayor activación o excitación, ya que, ayudan a la memoria y la activación del procesamiento cognitivo (Chung and Cheon 2015; Talarico et al. 2004). En la presente tesis se contemplaran las emociones relacionadas al aprendizaje en su valor de valencia y activación, debido al efecto de la dificultad (un aspecto del procesamiento cognitivo) en las emociones.

1.4. Emociones, aprendizaje y video juegos

La comunidad de jugadores ha reconocido la importancia de las emociones en el desarrollo de mejores juegos. Las emociones juegan un papel clave en la experiencia de usuario, tanto en el entretenimiento, como en el desarrollo de juegos serios para la educación, entrenamiento, evaluación, terapia o rehabilitación (Hudlicka 2008).

Los juegos serios se definen como el uso de juegos para ofrecer, apoyar y mejorar la enseñanza, el aprendizaje y la evaluación (Ghergulescu and Muntean 2012). Inicialmente los juegos serios tenían como enfoque principal el entrenamiento militar; sin embargo, se han ido expandiendo a otras áreas, provocando un alto crecimiento en el campo de investigación (Laamarti et al. 2014).

Los juegos serios ayudan a presentar objetivos atractivos para el estudiante, logran crear un alto nivel de inmersión lo que resulta benéfico en términos de aprendizaje cognitivo (Núñez Castellar et al. 2014), además, de que estos comparten las principales emociones experimentadas en el aprendizaje, ya que pueden ser aburridos cuando el reto es fácil, frustrantes o confusos cuando el reto es difícil de superar o entender, o causar inmersión cuando el reto es del nivel del jugador. Esta tesis se enfoca en el ambiente de los videojuegos para la aplicación del análisis de conducta y su inclusión para la clasificación de emociones, ya que, la dificultad puede dar información del estado emocional del jugador.

1.5. Motivación

La motivación de esta investigación incluye:

- Existen distintos trabajos acerca de juegos afectivos pero pocos de forma comercial por las limitaciones en el reconocimiento de emociones. Esta investigación busca usar dispositivos comerciales y mejorar la precisión de reconocimiento para crear juegos afectivos que se distribuyan de manera comercial.

- Las investigaciones que utilizan un análisis automatizado de conducta tienen un desempeño bajo a comparación de aquellos que hacen análisis de respuestas fisiológicas. La propuesta de esta tesis busca fusionar estos dos tipos de análisis de datos para lograr mejorar la detección de emociones.

1.6. Resumen de la propuesta

En esta tesis se propone el uso del análisis automatizado de conducta en conjunto con el análisis de respuestas fisiológicas para mejorar la precisión del reconocimiento de emociones, utilizando un dispositivo de bajo costo, en un entorno de videojuegos.

En el análisis automatizado de conducta se busca utilizar datos de los video juegos como son la puntuación y el número de errores. Para los datos de las respuestas fisiológicas se pretende analizar las señales del HR, el EDA, la presión arterial (BVP, del inglés: *Blood volume pulse*) y la SKT, utilizando un dispositivo de bajo costo.

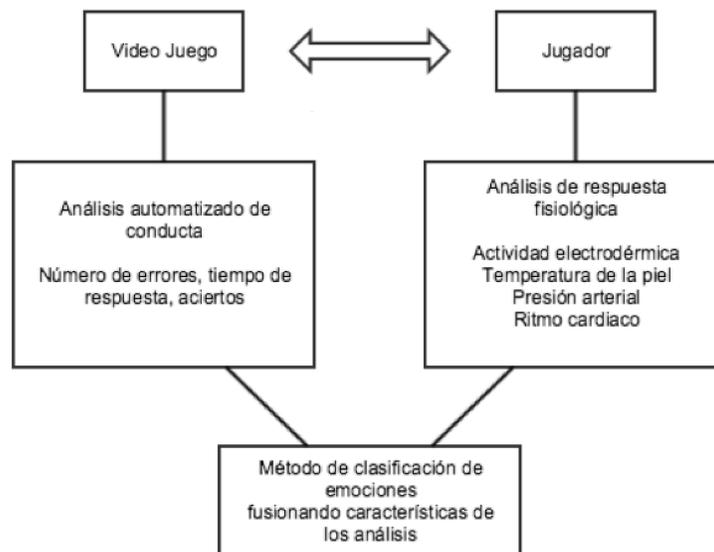


Figura 3: **Diagrama del método de clasificación de emociones**, usando fusión de características del análisis automatizado de conducta y el de respuesta fisiológica propuesto.

1.7. Objetivos

El objetivo general de esta tesis es la creación de un método de clasificación de emociones que use características obtenidas de datos fisiológicos y del análisis automatizado de conducta que permita mejorar la precisión de la detección en un entorno de videojuegos.

Para lograr el objetivo general se tomaron en cuenta los siguientes objetivos específicos:

- Identificar los modelos de clasificación de emociones utilizados en la literatura.
- Definir las señales fisiológicas y sus características que se usan con mayor frecuencia para clasificación de emociones.
- Investigar los trabajos de clasificación de emociones en entornos de videojuegos.
- Distinguir datos para el análisis automático de conducta en videojuegos.
- Comparar los métodos de clasificación estadística que se han empleado en la clasificación de emociones.
- Examinar los dispositivos encontrados en la literatura para la obtención de señales fisiológicas.
- Desarrollar un experimento con videojuegos para la obtención de datos del análisis automatizado de conducta, así como datos de las señales fisiológicas.
- Analizar los datos resultantes del experimento realizado para evaluar la técnica.
- Evaluar los resultados obtenidos.
- Comparar los resultados con los trabajos de la literatura.

1.8. Hipótesis

Esta tesis trata de validar la siguiente hipótesis:

- Se puede desarrollar un clasificador de emociones que fusione características de conducta, como es la interacción con el videojuego, y

características de señales fisiológicas; capaz de mejorar la precisión de detectores que sólo utilizan análisis de conducta y de aquellos que usan respuesta fisiológica.

1.9. Alcances y limitaciones

Debido a circunstancias que limitan el trabajo como lo son el tiempo y el presupuesto se consideraron las siguientes medidas para esta investigación:

- Dispositivos para datos fisiológicos: Se hizo énfasis en el uso de la pulsera empática e4 debido a que no se cuenta con algún dispositivo de alta precisión, así como el presupuesto para conseguir uno.
- Herramientas de clasificación: Para reducir el tiempo del análisis estadístico se utilizaron librerías estadísticas para un lenguaje de programación práctico, fácil de comprender y con un gran foro de programadores expertos (Python).
- Tipo de video juego: Debido a la gran diversidad de géneros de videojuegos se decidió sólo enfocarse en un videojuego casual, lo cual también reduce el tiempo de desarrollo del juego.
- Tamaño de la muestra y sesgo: los participantes del experimento se eligieron entre los estudiantes del centro de investigación en matemáticas unidad Zacatecas, esto debido a facilidad de horario y accesibilidad para realizar las pruebas.

1.10. Estructura de la tesis

Los capítulos siguientes de esta tesis se presenta: Capítulo 2 el marco teórico, con la información para entender el tema. Capítulo 3 los trabajos relacionados, para entender conocer las propuestas actuales. Capítulo 4 la propuesta realizada en base a la investigación. Capítulo 5 el experimento realizado y los resultados obtenidos. Finalmente Capítulo 6 los las conclusiones de este trabajo y los trabajos a futuro que se pueden derivar de esta investigación.

2.Marco teórico

En este capítulo se muestran conceptos relacionados con la propuesta como son los modelos de clasificación de emociones, la clasificación por medidas de respuesta fisiológica y por medidas de análisis de conducta. Finalmente un resumen de estos y su importancia en la propuesta.

2.1. Modelos de clasificación de emociones

Las emociones son un fenómeno complejo, difícil de entender. Para su estudio se han definido distintas teorías y conceptos, entre los que encontramos los modelos de clasificación de estas. Los estudios coinciden principalmente en dos tipos de clasificación, la discreta y la dimensional (Eerola and Vuoskoski 2011).

De acuerdo al modelo de clasificación de emociones discreto, todas las emociones pueden ser derivadas a base de un número limitado de emociones innatas, básicas y universales, como lo son, el miedo, la ira, el disgusto, la sorpresa, la tristeza y la felicidad (Ekman 1992). Cada emoción es independiente de las otras en su comportamiento, manifestación psicológica, y fisiológica, cada una surge de la activación de un canal neural único del SNC (Posner, Russell, and Peterson 2005). Estudios psicológicos han fallado en mostrar evidencia consistente que apoye esta teoría (Barrett T. 2006); es decir, los fundamentos neurológicos de las emociones básicas no ha sido validado, no se han establecido correlaciones fisiológicas para las emociones básicas, y no se ha identificado una expresión facial asociada con cada emoción básica (Posner, Russell, and Peterson 2005).

Médicos e investigadores han encontrado que las personas experimentan una dificultad para evaluar diferencias y describir sus propias emociones, debido a que las emociones pueden ser experiencias ambiguas (Saarni 1999). La solución a este problema son los modelos dimensionales, estos modelos tratan a las experiencias afectivas como estados continuos, ambiguos, altamente

interrelacionados (Posner, Russell, and Peterson 2005). El modelo con mayor aceptación es el modelo bidimensional o modelo circunplejo afectivo propuesto por (Russell 1980). Este modelo sugiere que los estados afectivos surgen de dos sistemas neurofisiológicos independientes, uno relacionado a la valencia, que dicta si el estado afectivo es agradable o desagradable, y el otro a la activación o desactivación. Cada emoción puede entenderse como una combinación lineal entre estas dos dimensiones, como se muestra en la Figura 4.



Figura 4: Representación gráfica del modelo circunplejo afectivo. El eje horizontal replanta la dimensión de la valencia y el eje vertical representa la dimensión de la activación.

2.2. Clasificación de emociones por señales fisiológicas

Como se menciona en el primer capítulo de esta tesis, existen dos enfoques principales en los sistemas de detección de emociones por análisis de respuesta fisiológica, el análisis del sistema nervioso central (SNC) y el análisis del sistema autónomo nervioso (SAN). El análisis del SNC utilizando el electroencefalograma (EEG); por otro lado, las señales del SAN: la actividad del ritmo cardiaco (HR, del inglés: *Heart rate*), la actividad electro-dérmica (EDA, del inglés: *Electro-dermal*

activity), la temperatura de la piel (SKT, del inglés: *Skin temperature*), la actividad de los músculos faciales (EMG) y la respiración (RESP) (Park et al. 2013).

Esta tesis se enfoca en las señales del EDA, HR, BVP y SKT, debido a que son las señales que podemos medir con la pulsera empática e4. A continuación se muestra una descripción de estas señales así como la relación que se ha visto con las señales fisiológicas.

2.2.1. Actividad electro dérmica.

La actividad electro-dérmica (EDA, del inglés: *Electro-dermal activity*), también conocida como respuesta galvánica de la piel (GSR, del inglés: *Galvanic skin response*), se refiere a los cambios en la capacidad de la piel para conducir electricidad. Es medida por técnicas relativamente no intrusivas que proveen información única acerca de diferentes aspectos cognitivos durante excitación emocional, incremento en la carga cognitiva, e inmersión en las actividades (Azevedo et al. 2016).

Se han hecho investigaciones utilizando imágenes como estímulo, los cuales muestran una alta correlación entre la excitación emocional reportada, también en el contexto de juegos digitales, ha reflejado respuestas emocionales y actividad cognitiva (Drachen et al. 2010).

Existen glándulas en las palmas de la mano y las plantas de los pies, las cuales causan la conductividad de la piel y dan lugar a la EDA. Por ejemplo, muchas personas tienen las manos frías y húmedas cuando están nerviosas (Mandryk and Atkins 2007). Existen tres modos relevantes en el EDA: niveles de actividad tónica o nivel de conductividad de la piel (SCL, del inglés: *Skin conductance level*), que es la actividad base; las respuestas fásicas o respuestas de conductividad de la piel (SCR, del inglés: *Skin conductance response*), referentes a impacto repentino de un estímulo; y las fluctuaciones espontáneas, las cuales no son específicas a la respuesta de conductancia de la piel (Azevedo et al. 2016). Se considera que a mayores valores de SCL, es más probable la presencia de la excitación emocional, así como la presencia de estímulos cuando existen niveles de SCR.

Algunas de las limitaciones que se deben tener en cuenta del EDA es que puede existir variación diaria en los participantes; por lo tanto, es imperativo recoger una lectura de línea base antes de cada sesión. Otras investigaciones contradicen estas recomendaciones (Figner and Murphy 2010). Estudios han demostrado que los niveles de EDA aumentan de forma lineal a lo largo del día, e incluso pueden ser influenciados por las estaciones del año (Azevedo et al. 2016).

2.2.2. Ritmo cardiaco.

El sistema cardiovascular ofrece una variedad de medidas para determinar la valencia y la excitación, como el ritmo cardiaco (HR, del inglés: *Heart rate*), el cual ha demostrado tener una correlación con la excitación de las personas (Drachen et al. 2010). El HR se refiere a la frecuencia de las contracciones del músculo cardíaco o miocardio. Además del HR otras mediciones de la actividad cardiovascular incluyen el intervalo entre latidos (IBI, del inglés: *Inter-beat interval*), variabilidad del ritmo cardiaco (HRV, del inglés: *Heart rate variability*), la presión arterial (BP, del inglés: *Blood pulse*) y el volumen de la presión arterial (BVP, del inglés: *Blood volume pulse*). El electrocardiograma (ECG) mide la actividad eléctrica del corazón, por lo que se puede obtener el HR, IBI y HRV del ECG, mientras que el BVP se puede obtener de sensores foto pletismógrafos (PPG, del inglés: *Photoplethysmogram*) (Mandryk and Atkins 2007). Debido a la relación entre estas medidas es posible calcular el HR y IBI aproximados a partir del BVP.

Existe evidencia significativa en la literatura que indica que la reactividad cardiovascular puede diferenciar no solo la intensidad de el estímulo, sino también la valencia, dependiendo de cómo se presenta el estímulo (Agrafioti, Hatzinakos, and Anderson 2012). La frecuencia cardíaca baja generalmente se asocia con un estado relajado o un estado en el que se experimentan estímulos agradables, mientras que las aceleraciones del HR ocurren en respuesta al ejercicio, los estados emocionales intensos, ruidos fuertes, la excitación sexual y el esfuerzo mental (Katsis, Katertsidis, and Fotiadis 2011). También se ha identificado que el HR incrementa bajo el miedo y la emoción, pero diferenciarlos es un reto (Agrafioti, Hatzinakos, and Anderson 2012). Investigaciones previas han validado

que la medición del volumen de la presión arterial es sensible al estrés y esta correlacionado con la ansiedad (Changchun Liu et al. 2009).

2.2.3. Temperatura de la piel

El sensor de temperatura en la piel (SKT, del inglés: *Skin temperature*) describe la temperatura medida en una superficie de la piel. Dado que los músculos están tensos bajo presión, los vasos sanguíneos se contraen y por lo tanto la temperatura disminuye. Igual que el EDA el SKT depende de factores externos como las estaciones del año. Además, es un indicador relativamente lento de los cambios en el estado emocional (Haag et al. 2004); sin embargo, se encontró un aumento significativo del SKT para la ira, en comparación a las otras emociones básicas (tristeza, alegría, miedo, sorpresa, y el disgusto). Investigaciones muestran que las personas que fueron estimuladas por música emocional su temperatura aumento con música positiva y calmada, mientras que disminuyo con piezas excitantes y negativas (Chanel et al. 2011). En otros estudios se encuentra que la SKT incrementa en el aburrimiento, muestra una alta disminución en casos de estrés, miedo, e incrementa durante la relajación y el sueño (E.-H. Jang, Park, Park, Kim, & Sohn, 2015). Estas emociones en valor de excitación y valencia, se traduce en que la SKT baja cuando hay presencia de excitación, principalmente si la valencia es negativa.

2.3. Clasificación de emociones por análisis automatizado de conducta

Algunas investigaciones muestran que la conducta de una persona, en base a su interacción con la computadora, puede reflejar su estado de ánimo (Baker et al. 2012).

Los trabajos enfocados en la clasificación de emociones por análisis automatizado de conducta tratan de lograr su objetivo sin el uso de sensores usados a la persona, para esto se han dividido en dos tipos, observación natural e interacción con la computadora (Christy 2014). La observación natural hace uso de las expresiones faciales, el pestañeo, los gestos, la postura y la modulación de

la voz para el reconocimiento de emociones; por otro lado, la interacción con la computadora revisa los patrones de uso, datos como la fuerza con que se presiona el mouse, comunicación entre la persona y el sistema, etc.

En la observación natural se han observado algunas limitante, para los datos como son los gestos, la postura y las expresiones faciales que hacen uso de la transmisión de video se requiere una alta capacidad de procesamiento por lo que se considera ineficiente (Fisher and Sanderson 1996); mientras que, en el análisis de la modulación de la voz se ha observado que las personas no se sienten cómodas hablando a un sistema (Jones and Deeming 2008), esto afecta la emoción de la persona y los resultados esperados.

2.4. Resumen

En el principio de este capítulo se analizaron los modelos de clasificación de emociones, los cuales se dividen en discretos y dimensionales. Los modelos discretos dictan que existen emociones básicas definidas; por otro lado, los modelos dimensionales usan variables para definir un estado emocional en un espacio. El modelo bidimensional o modelo circumplejo afectivo es el de mayor aceptación, utilizando valencia y activación para definir los estados emocionales. En este trabajo se decidió utilizar el modelo circumplejo afectivo para el representar estados afectivos.

Para la clasificación de emociones se pueden analizar la respuesta fisiológica o la conducta. El análisis de respuesta fisiológica puede estudiar respuestas del sistema nervioso central (SNC) o respuesta del sistema nervioso autónomo (SNA). Para esta tesis se decidió por el análisis del SNA, ya que la pulsera empática e4 puede obtener las señales del volumen de la presión arterial (BVP, del inglés: *Blood volume pulse*), la actividad electro-dérmica (EDA, del inglés: *Electro-dermal activity*) y la temperatura de la piel (SKT, del inglés: *Skin temperature*), los cuales son parte del SNA.

En el análisis automatizado de conducta se mostraron dos tipos, la observación natural y la interacción con la computadora. El primero consiste en identificar

cambios en la persona, principalmente expresiones faciales y su modulación de la voz; mientras que, la interacción con la computadora analiza patrones de la interacción con los sistemas. Este estudio se limita a solo el uso de la pulsera e4, para complementar el análisis de conducta se considera la interacción usuario – computadora enfocado a videojuegos.

3. Trabajos relacionados

En este capítulo se revisan los trabajos relacionados a esta tesis. Un breve resumen de los esfuerzos de la clasificación por respuesta fisiológica, así como los logros en trabajos que utilizan análisis de conducta, y una comparación de estos con la propuesta de este trabajo.

3.1. Trabajos relacionados al análisis de respuesta fisiológica

Para tener un mejor entendimiento de que cambios que presentan las señales, se investigó los trabajos más relevantes de la clasificación de emociones por análisis de respuesta fisiológica que utilizaran las señales del EDA, HR, BVP y SKT. En las tablas Tabla 2 a la Tabla 6 se muestra los trabajos relacionados, las emociones que detectan, las señales que usan, las características que usan, el clasificador estadístico utilizado, y la precisión que logran. Todos los acrónimos usados en estas tablas se describen en la Tabla 7 y Tabla 8.

Tabla 2: Trabajos de clasificación de emociones por análisis de respuesta fisiológica (Parte 1).

Autor	Emoción	Señal	Características	Clasificador	Precisión
(Friedrichs et al., 2015).	Niveles de efecto positivo o negativo	EDA	DS SCL, DS SCR, Pendiente de la aproximación lineal del SCL.,	SVM	70%
		ECG	M, DS, RMS RR, RMS DS, IBI, LF, HF		
(Guendil et al., 2015)*	Excitación, Valencia	EMG	Fusión de características basadas en la transformada de ondula	SVM	95%
		RESP			
		EDA			
		ECG			
(Jang, Park, Park, Kim, & Sohn, 2015)	Aburrimiento, Dolor, Sorpresa	ECG	BVP, PTT, HR, HF, LF, HRV	LDA	74.90%
		EDA	SCR		
		SKT	M		
(Valenza, Citi, Lanatá, Scilingo, & Barbieri, 2014)	Excitación, Valencia	ECG	Estimación dinámica biespectral, estimación dinámica triespectral, estimación exponente dominante Lyapunov	SVM	79.90%
(Park et al., 2013)	Feliz, Triste	SKT	promedio	SVM	92.41%
		ECG	IBI promedio		

Tabla 3: Trabajos de clasificación de emociones por análisis de respuesta fisiológica (Parte 2).

Autor	Emoción	Señal	Características	Clasificador	Precisión
E. Jang et al., 2013)	Aburrimiento, Dolor, Sorpresa	ECG	BVP, PTT, HR, HF, LF, HRV	LDA	74.90%
		EDA	SCR		
		SKT	M		
(Selvaraj et al., 2013)	Neutral, Feliz, Triste, Miedo, Sorpresa, Disgusto	ECG	Hurst usando FVS	FKNN	92.87%
(Valenza, Citi, Lanata, Scilingo, & Barbieri, 2013)	2 niveles de excitación y valencia	ECG	Estimación dinámica biespectral, Estimación dinámica trispectral	NARI	90%
(Valenza et al., 2012)	Excitación, Valencia	EDA	Caos determinista, Diagrama recurrente(DLE, RR, DET, LAM, TT, Ratio, ENTR, Lmax), Análisis de fluctuación sin tendencia	QDA	76%-100%
		ECG			
		RESP			
(Nogueira, Rodrigues, Oliveira, & Nacke, 2013)	Excitación, Valencia	ECG	Modelos de regresión	Fusión de modelos	~90%
		EDA			
		EMG			
(Nogueira, Rodrigues, & Oliveira, 2013)	Excitación, Valencia	ECG	Modelos de regresión	Ponderación RSS	~70%-85%
		EDA			
		EMG			
(Chanel et al., 2011)	Excitación, Valencia	EDA	M, MD, MDNV, número de caídas de la resistencia en la señal, proporción de muestras negativas de la derivada vs. Todas las muestras	QDA	59%
		ECG	BVP M, DS, HR M, MD, DS, LF, HF, Razón de energía (LF/HF)		
		RESP	Frecuencia, DS, Max. Min.		
		SKT	M, MD		
(Katsis, Katertsidis, & Fotiadis, 2011)	Relajado, neutral, sorprendido, aprensivo, muy aprensivo	ECG	BVP M, DS	ANN, SVM	84%
		EDA	M, MAFD, Tasa de respuestas del EDA		
		RESP	M, MAFD, Ritmo respiratorio		

Tabla 4: Trabajos de clasificación de emociones por análisis de respuesta fisiológica (Parte 3).

Autor	Emoción	Señal	Características	Clasificador	Precisión
(Kim & André, 2008)	4 Emociones musicales	ECG	110 características	LDA	70%-95%
		EMG			
		EDA			
		RESP			
(Yannakakis & Hallam, 2007)	2 niveles de diversión	ECG	Promedio, DS, Min, Max, Diferencia entre Max. y Min. Inicial HR, Ultimo HR, Tiempo de Max HR, tiempo de Min HR, Diferencia de tiempo entre Max. Min., Auto correlación, Correlación entre HR y tiempo, Entropía aproximada, BVP Promedio DS, Min, Max, Promedio amplitud entre pulsos, MFD, MAD	SVM, ANN	~70%
		EDA	Todas las Usadas en HR		
(Katsis, Katertsidis, Ganiatsas, & Fotiadis, 2008)	Alto estrés, bajo estrés, decepción, euforia	EMG	M, RMS	SVM	79.30%
		ECG	M, MFD		
		RESP	M, MFD		
		EDA	M, Tasa de conductancia MFD, M duración del aumento		
(Liu, Conn, Sarkar, & Stone, 2008)	Inmersión, Gusto, Ansiedad	ECG	Potencia simpática, parasimpática, potencia de muy baja frecuencia, relación de potencias. M IBI, DS IBI, M, DS valores pico, M tiempo de transito del pulso	SVM	83%
		Sonido del corazón	M y DS de los niveles de coeficiencia 3°,4°,5° de la transformada de onda de Daubechies del sonido del corazón		
		Bioimpedancia	M periodo pre-eyección, IBI		
		EDA	M e inclinación de SCL		
			M, Max SCR		
		Tasa de SCR			
		EMG	M, DS e Inclinación de actividad superciliar, parpadeo, cigomático y trapecio		
SKT	M, DS e inclinación de temperatura				

Tabla 5: Trabajos de clasificación de emociones por análisis de respuesta fisiológica (Parte 4).

Autor	Emoción	Señal	Características	Clasificador	Precisión
(Zhai & Barreto, 2006)	2 niveles de estrés	ECG	BVP, M DS IBI, razón LF/HF	SVM	90%
		EDA	Tasa de SCR, M SCL, Tiempo de incremento de SCR		
		SKT	Inclinación de temperatura		
		Actividad pupilo gráfica	M diámetro de la pupila		
(Rani, Liu, Sarkar, & Vanman, 2006)	Inmersión, Ansiedad, Aburrimiento, Frustración e Ira	ECG	M tiempo de transito del pulso	SVM	86%
		Sonido del corazón	M y DS de los niveles de coeficiencia 3°,4°,5° de la transformada de onda de Daubechies del sonido del corazón		
		Bioimpedancia	M periodo pre-eyección, IBI		
		EDA	M e inclinación de SCL, M, Max SCR, Tasa de SCR		
		EMG	M, DS e Inclinación de actividad superciliar, parpadeo, cigomático y trapecio		
		SKT	M, DS e inclinación de temperatura		
(Li & Chen, 2006)	Miedo, neutral, alegría	SKT	M, diferencia de Max. Min. (segmentos 1 min.)	CCA	85.30%
		EDA	Primer diferencia		
		RESP	Ritmo respiratorio, inspiratoria máxima		
		ECG	M HR, rango Min - Max, HF, LF, M NN, SD NN M onda T de amplitud simpática y parasimpática M DS onda R, , RMS DS		
(Yoo, Lee, Park, Kim, & Lee, 2005)	Tristeza, placer calmado, placer interesante, miedo.	ECG	DS NN, RMS DS, LF/HF	ANN	80%
		EDA	Amplitud		
(K. H. Kim, Bang, & Kim, 2004)	Tristeza, ira, estrés, sorpresa	ECG	M, DS, diferenciación	SVM	61.80%
		EDA	Cálculo de SCR		
		SKT	M, Max.		

Tabla 6: Trabajos de clasificación de emociones por análisis de respuesta fisiológica (Parte 5).

Autor	Emoción	Señal	Características	Clasificador	Precisión
(Haag, Goronzy, Schaich, & Williams, 2004)	Excitación, Valencia	EMG	M, DS, inclinación	ANN	90%-96%
		ECG	M, DS, inclinación, HRV, IBI		
		RESP	M, DS, inclinación		
		SKT	M, DS, inclinación		
		EDA	M, DS, inclinación		
(Lisetti & Nasoz, 2004)	Tristeza, ira, miedo, sorpresa, frustración y diversión	ECG	Min. Max. M, DS	MBA	84%
		EDA	Min. Max. M, DS		
		SKT	Min. Max. M, DS		
(Picard, Vyzas, & Healey, 2001)	Neutral, ira, odio, pesar, amor platónico, amor romántico, alegría, veneración	EMG	M,DS, MAFD, MASD	LDA	81%
		ECG	M,DS, MAFD, MASD		
		EDA	M,DS, MAFD, MASD		
		RESP	M,DS, MAFD, MASD		

Tabla 7: Acrónimos (Parte 1) de señales fisiológicas, de características de las señales y clasificadores estadísticos.

Acrónimo	Señales fisiológicas
EDA	Actividad Electro dérmica
ECG	Electrocardiograma
RESP	Actividad respiratoria
EMG	Electromiografía
SKT	Temperatura de la piel
HR	Ritmo Cardíaco
BVP	Volumen de la presión arterial
Acrónimo	Características
M	Media
DS	Desviación estándar
Min.	Mínimo
Max.	Máximo
MFD	Media de la primera diferencia
MAFD	Media absoluta de la primera diferencia
MASD	Media absoluta de la segunda diferencia
MD	Media del derivado

Tabla 8: Acrónimos (Parte2) de señales fisiológicas, de características de las señales y clasificadores estadísticos

Acrónimo	Características
MDNV	Media del derivado de los valores negativos
RMS	Media de la raíz cuadrada
IBI	Intervalo entre latidos
LF	Baja Frecuencia
HF	Alta Frecuencia
NN	Intervalo NN
RR	Intervalo RR
HRV	Variabilidad del ritmo cardiaco
SCR	Respuesta de conductividad de la piel
SCL	Nivel de conductividad de la piel
Acrónimo	Clasificador
LDA	Análisis de discriminación lineal
SVM	Máquina de vectores de soporte
QDA	Análisis de discriminación cuadrática
ANN	Red neural artificial
CCA	Análisis de correlación canónica
FKNN	K vecino más cercano con lógica difusa
MBA	Retro propagación Marquardt
NARI	Modelo no lineal autor regresivo integrado

En estas investigaciones podemos observar que la mayoría de los trabajos se enfocan en los modelos de clasificación de emociones discretos y dimensionales. De las emociones básicas discretas, existen más trabajos que estudian felicidad y tristeza, mientras que algunos trabajos buscan clasificar emociones secundarias o complejas como el aburrimiento y la inmersión.

Estos trabajos analizan características básicas como son la media, la desviación estándar, el máximo y el mínimo de las distintas señales, sólo algunos de ellos exploran medidas más complejas. Las medidas complejas se ven principalmente en el análisis del ritmo cardiaco, medidas no lineales como la

entropía, el exponente de Lyapunov y el exponente de Hurst (Selvaraj, et. al, 2013; Valenza, Lanata, & Scilingo, 2012).

Se observa que el clasificador estadístico utilizado en la mayoría de estas investigaciones es la máquina de soporte vectorial, seguido por el análisis de discriminación, ya sea cuadrático o lineal, y el uso de redes neuronales. Aun cuando algunos de estos trabajos usan señales, características y clasificadores estadísticos similares, la efectividad de los trabajos varía del 70% a 95%, esto se debe a que la metodología experimental que se usa en cada trabajo difiere y no hay una línea base para su comparación.

En los trabajos investigados resalta el uso del clasificador SVM. Una de las razones es la capacidad de una alta precisión del 95% usando varias señales fisiológicas (Guendil et al. 2015). Otra característica de este clasificador es la capacidad de lidiar con datos ruidosos y el sobreajuste, esto lo hace en particular adecuado para el reconocimiento afectivo, ya que, los datos fisiológicos son ruidosos y normalmente el conjunto de entrenamiento es pequeño (Rani et al. 2006). De igual manera el clasificador de QDA muestra una precisión del 76% al 100% (Valenza et al. 2012), por lo que en este trabajo se considero como uno de los clasificadores a analizar para la propuesta.

Los sensores de alta precisión y toma de muestra con frecuencia alta utilizados en los estudios (Guendil et al. 2015; Valenza et al. 2012) son de alto costo difícilmente transferible para propósitos de uso masivo.

En esta tesis se realizó un estudio comparativo de la precisión de los clasificadores SVM y QDA con las características de las señales HR, BVP, SKT y EDA de un dispositivo tipo pulsera comercial.

3.2. Trabajos relacionados al análisis automatizado de conducta.

Para la clasificación de emociones a través del análisis automatizado de conducta se pueden dividir en tres enfoques principales; el análisis de expresiones

faciales, la revisión de la modulación de la voz, y la interacción con la computadora.

El reconocimiento automático de expresiones faciales lleva como tema de la ciencia en computación por más de dos décadas, su importancia es tal que se han hecho retos como el realizado en la conferencia de la IEEE acerca del reconocimiento automatizado de caras y gestos en el 2011 (Valstar et al. 2012). El trabajo ganador de este concurso logró un 83.8% de precisión (Yang and Bhanu 2011); sin embargo, aun quedan retos por superar como considerar la rotación de la cabeza fuera del plano, expresiones espontáneas, reconocer mezcla de emociones (Valstar et al. 2012). Otro factor en contra del análisis de expresiones faciales es que es propenso a enmascaramiento social o expresiones artificiales, esto es, que las expresiones faciales pueden ser fingidas y no representar el verdadero estado emocional de la persona (Selvaraj et al., 2013).

En la clasificación de emociones por análisis de la modulación de la voz, (Anagnostopoulos, Iliou, and Giannoukos 2012) hacen una revisión en la que muestran el resultado de distintos trabajos en esta área. Estas investigaciones presentan un rendimiento que van desde el 50% al 90%, (Anagnostopoulos, Iliou, and Giannoukos 2012) hacen énfasis en que hay una falta de uniformidad en la que los métodos son evaluados, por lo que es inapropiado hacer una comparación directa y declarar explícitamente cuales métodos demostraron el mejor desempeño, además de señalar que no se ha encontrado un conjunto de características de la voz que se consideren los mejores para el análisis. A estos problemas se le suma que el análisis de la modulación de la voz, al igual que el análisis de expresiones faciales es propenso a emociones artificiales (Selvaraj et al., 2013).

Una de las áreas donde principalmente se ha utilizado el análisis por medio de interacción con la computadora es en los sistemas de aprendizaje. (S. K. D'Mello et al. 2008) modela el estado afectivo del estudiante usando solo archivos de registro del sistema inteligente de tutorías Auto Tutor. El modelo logra distinguir entre un conjunto discreto de emociones (felicidad, tristeza, ira, disgusto, sorpresa)

y otra neutral, pero falla al distinguir entre emociones. En otra investigación (Sabourin, Mott, and J. 2011) estudian el estado afectivo de los estudiantes usando la *Isla de cristal*, un ambiente educativo centrado en la narrativa, donde estudiaron una combinación de cuestionarios con registros del sistema para predecir los estados afectivos auto reportados por los estudiantes. Su modelo identifica 38% mejor que el porcentaje base los estudiantes concentrados y 24% mejor que el porcentaje base los estudiantes curiosos, pero tiene poca éxito en identificar estudiantes confundidos, frustrados o aburridos. Como estos existen otros trabajos donde el principal problema es la baja precisión que obtienen para distintas emociones, además de que los análisis varían según el sistema que se utiliza.

3.3. Comparación con la propuesta

Una vez revisados algunos de los trabajos que se han hecho en la clasificación de emociones por medio del análisis de respuesta fisiológica, así como el análisis automatizado de conducta podemos hacer las siguientes comparaciones.

Respecto a las investigaciones del análisis de respuesta fisiológica, estos trabajos tienen un porcentaje de rendimiento alto, sin embargo utilizan sensores que pueden ser estorbosos para los sujetos de prueba, además de que sólo han sido utilizados en entornos de laboratorios. En este trabajo se propone el uso de una pulsera comercial, la pulsera empática e4, la cual tiene menor rendimiento que los sensores que usan los trabajos investigados, pero permite su uso fuera de un laboratorio. Las principales señales analizadas en los trabajos de análisis de respuesta fisiológica son el ritmo cardíaco (HR, del inglés: *Heart rate*), el volumen de la presión arterial (BVP, del inglés: *Blood volume pulse*), la actividad electro-dérmica (EDA, del inglés: *Electro-dermal activity*), la temperatura de la piel (SKT, del inglés: *Skin temperature*) y la respiración (RESP), debido al uso de la pulsera e4, para este trabajo se consideraron las señales del BVP, HR, EDA y SKT. Entre los clasificadores estadísticos utilizados para estos análisis se encontraron la máquina de soporte vectorial (SVM, del inglés: *Support vector machine*), el análisis discriminante lineal (LDA, del inglés: *Linear discriminant analysis*), cuadrático

(QDA, del inglés: *Quadratic discriminant analysis*) y las redes neuronales artificiales (ANN, del inglés: *Artificial neural network*), por lo que para este trabajo se considero analizar la clasificación utilizando SVM y QDA, debido a que presentaron mayor precisión que los demás clasificadores.

Se debe mencionar que algunas de las investigaciones presentadas sólo clasifican un conjunto de emociones discretas (E.-H. Jang et al. 2015; Katsis, Katertsidis, and Fotiadis 2011; Lisetti and Nasoz 2004; C Liu et al. 2008; Park et al. 2013; Rani et al. 2006; Selvaraj et al. 2013; Zhao et al. 2012). Esta tesis busca clasificar en base a la valencia y activación de acuerdo al modelo circuplejo de Russell, como lo plantean (Chanel et al. 2011; Guendil et al. 2015; Haag et al. 2004; Nogueira et al. 2013; Valenza et al. 2012). Esto permite una evaluación más acertada del estado emocional.

En el análisis automatizado de conducta se expuso tres principales enfoques, el análisis de expresiones faciales, la modulación de la voz, y la interacción con la computadora. El análisis de expresiones faciales y la modulación de la voz han logrado un desempeño que si bien no es tan alto como el del análisis de respuesta fisiológica es mejor que adivinar; sin embargo, estos métodos pueden ser fingidos o simulados, entre otras limitantes, por lo que para esta tesis se considero usar el análisis de interacción con la computadora. Los trabajos hechos con análisis con interacción con la computadora son los que muestran el peor desempeño entre los métodos analizados, para evitar este problema esta tesis fusiona las características de este método con el análisis de respuesta fisiológica, mejorando el desempeño para obtener una correcta clasificación de emociones.

4. Propuesta

En este capítulo se describe el método propuesto, las señales fisiológicas elegidas, las características del análisis de respuesta fisiológica que se tomaran de estas señales, las características del análisis automatizado de conducta tomadas del videojuego y los clasificadores estadísticos donde se probaran las características seleccionadas

4.1. Señales fisiológicas

Como se mencionó con anterioridad, uno de los objetivos de la tesis es el uso de la pulsera empática e4, esto representa una alternativa a los sensores comúnmente usados. La pulsera empática e4 permite la lectura de las señales del EDA, BVP y el SKT; además, es capaz de calcular el HR a partir del BVP. De acuerdo a la literatura revisada, existe una correlación entre el aumento o disminución de estas señales y la presencia de activación así como de valencia positiva o negativa, por lo que el método debería ser capaz de hacer una clasificación utilizando estas señales que se pueden obtener con la pulsera empática e4.

4.2. Características

Una característica es una cualidad típica o importante de algo. Para la clasificación de emociones algunos autores dividen estas características en dos categorías, características estándar y características no-lineales (Valenza, Lanata, and Scilingo 2012). Este trabajo se analizan características estándar, las cuales se refieren a características derivadas de: series de tiempo, estadísticas, dominio de la frecuencia y análisis geométrico de las señales.

4.2.1. Características de análisis de respuesta fisiológica

De acuerdo a la investigación realizada, se busca encontrar el incremento o disminución en el valor de las señales, para esto se tomaron medidas estadísticas que se encontraron en la mayoría de los artículos, las cuales se presentan a continuación. Sea X una señal discreta (v.g. EDA, BVP, SKT y HR) con valores

secuenciales ($X_1, X_2 \dots X_n$) tomados en un lapso de tiempo (v.g.. 10 segundos). Se definen las siguientes características:

Media(μ_x):

$$\mu_x = \frac{1}{N} \sum_{n=1}^N X_n$$

Desviación estándar(σ_x):

$$\sigma_x = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (X_n - \mu_x)^2}$$

Además de estas medidas se decidió calcular la Entropía de Shannon (ShEn) del HR. Como se ha reportado en la literatura, el ritmo senoidal de la variación del HR se caracteriza por ser similar al caos determinístico (Hagerman et al. 1996), debido a esto se han probado distintos análisis no lineales como la ShEn para su estudio. La ShEN provee una medida cuantificable para la incertidumbre de una variable aleatoria, lo que nos muestra si una señal que tiende a un patrón es regular (Yoon et al. 2015). Este valor nos permite conocer si el HR esta cambiando constantemente, lo cual es una señal de un estado emocional con excitación. Para calcular el ShEn se ordenan los datos del HR en espacios de tamaños iguales definidos por los valores mínimo y máximo obtenido. La distribución de probabilidad $p(n)$ es calculada para cada espacio como el número de datos de HR en cada espacio dividido por el número total de datos en el segmento, y la ShEn se define como:

$$ShEn = - \sum_{n=1}^{Nr} p(n) \frac{\log p(n)}{\log \frac{1}{Nr}}$$

donde Nr es el número de espacios.

Tomando en cuenta las recomendaciones de la señal del EDA, se decidió tomar una señal base, de manera que la característica tomada de la señal del EDA esta

en función a la relación de cambio entre la media de la señal base y la media de la señal durante la sesión del experimento.

4.2.2. Características de la conducta.

Como se expuso en el capítulo 2 la conducta del jugador puede reflejar su estado afectivo (Baker et al. 2012). Para esta tesis se toma como medida la puntuación máxima del jugador en la sesión $pMax$, el número de intentos de la sesión i , así como la relación entre estas dos medidas $\frac{pMax}{i}$ para analizar la conducta del jugador, bajo la hipótesis de que una buena puntuación puede indicar que el jugador está inmerso o el reto es fácil y se aburre, mientras que una mala puntuación indica que está frustrado. Esta hipótesis surge de la teoría del flujo, la cual nos habla acerca del desarrollo personal es en base a los retos y las habilidades (Csikszentmihalyi 2014). Como se ve en la Figura 5, el flujo, que se refiere a un estado de la mente caracterizado por una concentración enfocada y un elevado disfrute durante una actividad intrínsecamente interesante (Csikszentmihalyi 2014). El flujo es el estado emocional que se busca para el desarrollo del conocimiento, este estado puede caer en aburrimiento cuando las habilidades de la persona son superiores a el reto que se le presenta, o en frustración o ansiedad cuando el reto es mayor a sus habilidades.

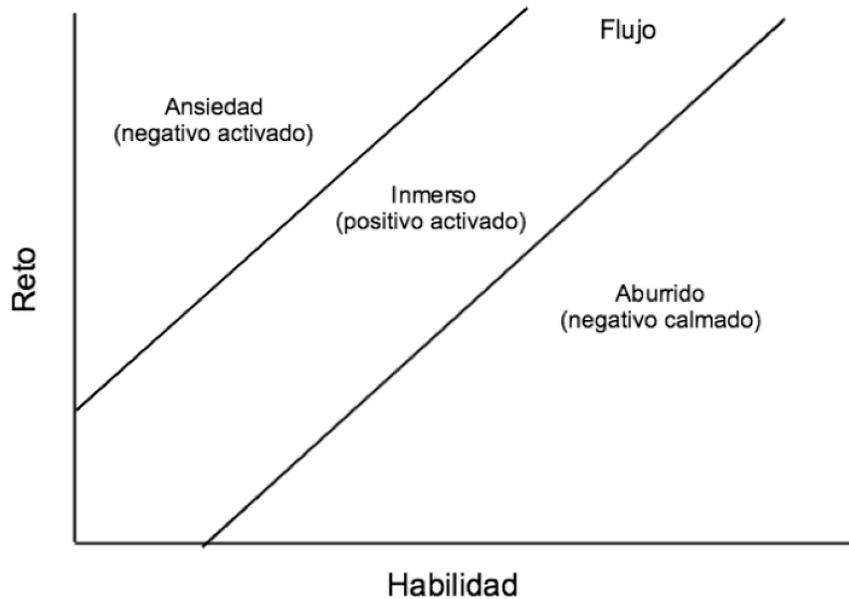


Figura 5: *Modelo del flujo* (Csikszentmihalyi 2014). Estados emocionales según el reto de una tarea y la habilidad de una persona.

Es importante mencionar que el comportamiento de las características de la puntuación y el número de intentos cambia dependiendo del diseño del videojuego. De manera que es necesario revisar las métricas para el análisis de conducta según diseño del videojuego.

4.2.3. Característica de salida

Para clasificar la emoción se utilizó como medida de salida la valencia y la activación. Estos valores se obtuvieron mediante el uso del SAM previamente descrito en la introducción de este trabajo. Se realizó una implementación, la cual se describe más en el capítulo siguiente, para tener datos con los cuales entrenar el clasificador elegido.

4.3. Clasificador

Determinar la valencia y excitación de un estado afectivo en particular desde una respuesta fisiológica y otras características de conducta en el juego es un problema de clasificación. En este problema de clasificación la función objetivo es el grado de excitación y valencia (Rani et al. 2006). Para este trabajo se eligió trabajar con la máquina soporte vectorial (SVM, del inglés: *Support vector*

machine), así como el análisis discriminante cuadrático (QDA, del inglés: *Quadratic discriminant analysis*) los cuales se explican a continuación.

4.3.1. SVM

El SVM es un modelo no lineal, que se ha utilizado para el reconocimiento de emociones (E.-H. Jang et al., 2015). La máquina de soporte vectorial es una máquina lineal que trabaja con un espacio de elevada cantidad de características de k dimensiones formado por un arreglo de X datos de entrada de dimensiones n (v.g. Un vector de características derivadas de señales fisiológicas) en un espacio de características k dimensional ($k \ll n$) a través del uso de un mapeo no lineal $f(X)$. Esto permite el uso de álgebra lineal y la geometría para separar los datos normalmente sólo separables con reglas no lineales en el espacio de entrada. El problema de encontrar un clasificador de datos dados con etiquetas de clase conocidos puede ser descrito como encontrar un hiperplano que separa $W^T \varphi(X)$ que satisface:

$$y_i(W^T \varphi(X_i)) = y_i \left(\sum_{j=1}^k w_j \phi_j(X_i) + w_0 \right) \geq 1 - \xi_i$$

para $i = 1, 2, \dots, N$

donde $y_i \in \{+1, -1\}$ representa la etiqueta de clase (ej. Baja / Alta activación o valencia); N es el número de pares de datos de entrenamiento (X_i, y_i) ; $\varphi(X) = [\phi_0(X), \phi_1(X), \dots, \phi_k(X)]^T$ es el vector de características mapeadas ($\phi_0(X) = 1$); y $W = [w_0, w_1, \dots, w_k]$ es el vector de ponderación de la red. La variable de holgura no negativa ξ_i generaliza el clasificador lineal con un margen suave para lidiar con los problemas no linealmente separables, en los que el margen se define como la suma de las distancias del hiper-plano de los puntos de datos más cercanos de cada una de dos clases (C Liu et al. 2008b).

Para permitir el cálculo eficiente de los productos internos directamente en el espacio de características y eludir la dificultad de especificar el mapeo no lineal de forma explícita, todas las operaciones en los modelos de aprendizaje y las

pruebas realizadas en SVM son utilizando las denominadas funciones del kernel que cumplen las condiciones de Mercer (Vapnik 1998). La función kernel seleccionada fue la función de base radial (RBF del inglés: *Radial basis function*) por que en otras investigaciones muestra mejor desempeño (Rani et al. 2006).

El atractivo del SVM reside en su fuerte asociación con la teoría del aprendizaje estadístico, ya que se aproxima al principio de minimización del riesgo estructural. El uso de SVM es capaz de lidiar con datos ruidosos y el sobreajuste al permitir algunas clasificaciones erróneas en el conjunto de entrenamiento. Esto lo hace en particular adecuado para el reconocimiento afectivo, ya que, los datos fisiológicos son ruidosos y normalmente el conjunto de entrenamiento es pequeño (Rani et al. 2006).

Para el uso de este clasificador se utiliza la implementación integrada en la librería para Python *Scikit-learn*, además de que las características son extraídas de los datos usando código en Python para su fácil integración.

4.3.2. QDA

QDA es un clasificador basado en el teoría de decisión de Bayesiana, minimiza el riesgo general, garantizando la tasa de error promedio más bajo. Usando la regla de Bayes, el clasificador busca la clase con la mayor probabilidad posterior $P(\omega_i|f)$. Bajo la suposición de que las distribuciones condicionales $P(f|\omega_i)$ siguen una distribución Gaussiana con diferentes medias μ_i y matrices de covarianza Σ_i , esta regla define automáticamente un límite de decisión cuadrática:

$$P(\omega_i|f) = \frac{P(f|\omega_i)P(\omega_i)}{\sum_{i=1}^C P(f|\omega_i)P(\omega_i)} = \frac{N(f|\mu_i, \Sigma_i)P(\omega_i)}{\sum_{i=1}^C N(f|\mu_i, \Sigma_i)P(\omega_i)}$$

Vectores μ_i y matrices Σ_i son obtenidos del conjunto de entrenamiento. Aquí la probabilidad $P(\omega_i)$ esta definido como $1/K$, donde K es el número de clases (Chanel et al. 2009).

Este clasificador también se puede utilizar por medio de la librería *Scikit-learn*, además de que en la revisión de la literatura se encontraron trabajos donde tenía una alta precisión, por lo que se considero su uso para este trabajo.

4.4. Resumen de la propuesta

En resumen la propuesta fusiona las características de la respuesta fisiológica y la conducta para la clasificación de emociones. De la respuesta fisiológica toma la media, la desviación estándar de las señales del EDA, BVP, HR y SKT, así como la entropía de Shannon del HR. Para el análisis de conducta se toman los datos de puntuación y número de intentos del video juego utilizado.

Las características obtenidas son utilizadas en un clasificador estadístico SVM y QDA para obtener una clasificación de las emociones provocadas por el experimento. En la Tabla 9 se muestra el resumen de la propuesta de esta tesis.

Tabla 9: Propuesta del método de clasificación de emociones. Resumen del clasificador, características fisiológicas y de conducta tomadas por este trabajo y sensor utilizado en el experimento.

Clasificador	SVM o QDA
Características fisiológicas	HR (Media (M), Desviación estándar (DE), Entropía de Shannon (ShEn)) EDA (M, DE, M base / M medida) BVP (M, DE) SKT (M, DE)
Características de Conducta	Puntuación máxima (Pmax), número de intentos (i), puntos por intento (Pmax/i)
Sensor usado	Empática E4 (PPG, GSR, termómetro infrarrojo)

5. Experimentación

En este capítulo se explora la efectividad del método de clasificación propuesto. Se describe el diseño del experimento realizado, los participantes, la metodología empleada para realizarlo, las métricas que se tomaron y los resultados obtenidos.

5.1. Diseño del experimento

Similar a otros experimentos reportados en la literatura (Chanel et al. 2011), este experimento consiste en inducir emociones por medio de la dificultad de un videojuego, con el objetivo de obtener datos de respuesta fisiológica con la pulsera e4 y de datos de conducta del videojuego utilizado. Una vez obtenidos estos datos, se calculan las características propuestas y se entrena el clasificador estadístico para probar la efectividad del método.

5.2. Participantes

En este experimento participaron ocho personas (cinco hombres y tres mujeres) con un rango de edades entre 24 a 30 años. Los participantes no habían consumido bebidas como alcohol o café, además de no haber realizado ejercicio tiempo antes de la prueba, para evitar alteraciones en los datos. Se registraron tres sesiones por participante, una para cada dificultad, obteniendo 24 sesiones de cinco minutos, de estas sesiones dos tuvieron errores en los datos por lo que al final fueron 22 sesiones.

5.3. Videojuego

En esta investigación se decidió utilizar el juego de *Dizzy Route*, debido a que se tiene acceso al desarrollo de este para la manipulación del mismo, lo cual no solo nos permite modificar la dificultad, si no también integrar el cuestionario del SAM y generar los casos de prueba de manera automatizada para intervenir lo menos posible en la sesión de juego del participante.

El juego consiste en manejar un carro por un camino zigzagueante, el jugador utilizará el toque en la pantalla para hacer girar el carro, evitando caer del camino.

Además en el camino se encontrarán monedas que incentivan al jugador, así como botellas, las cuales provocan giros en la cámara del juego, lo cual puede provocar que el jugador salga de control y pierda el juego; sin embargo, incrementan la puntuación del jugador.

El juego fue modificado para generar sesiones de juego de cinco minutos, al jugador se le presentan tres sesiones. En cada una de ellas el jugador utiliza un vehículo distinto, los cuales tienen una diferente aceleración, ya que esta aceleración es el principal factor que afecta la dificultad del juego. Cada vehículo representa una dificultad distinta como se muestra en la Tabla 10.

Tabla 10: Relación entre vehículo y dificultad del juego.

Vehículo	Dificultad
Camión lento	Fácil
Carro normal	Normal
Ambulancia rápida	Difícil

Como se menciona en el capítulo anterior, se agregó también una pantalla para que el participante realice una auto-evaluación con el SAM para obtener los datos de valencia y activación de la persona. En la Figura 6 se muestran algunas interfaces del juego. En la Figura 6(a) se muestra el juego normal en el que se conduce el carro, teniendo solo un botón de reinicio y la puntuación en la parte superior, mientras que en la Figura 6(b) se muestra el SAM que se le presenta al jugador, con barras deslizadoras para seleccionar el valor en base a las imágenes, y un contador de tiempo para que identifique el tiempo que tiene para contestar.

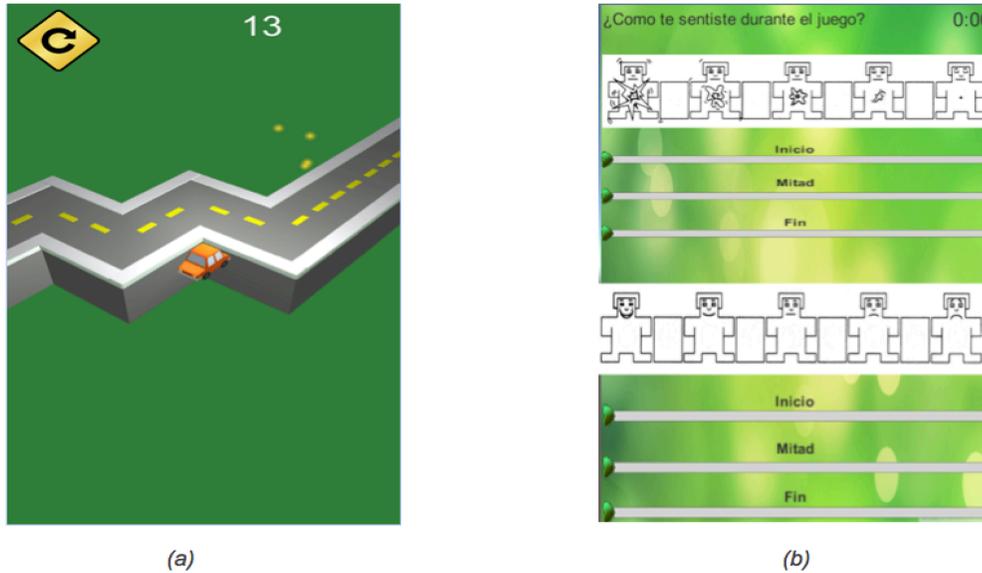


Figura 6: *Juego Dizzy Route*. (a) pantalla de juego, (b) pantalla de auto-evaluación del SAM.

5.4. Procedimiento

Se colocó la pulsera empática e4 en la muñeca izquierda para evitar que los movimientos fuertes que pudiera ocasionar el juego en la mano derecha causaran pérdida de datos. Se procuró que el lugar del experimento no tuviera distracciones para que el sujeto se pudiera concentrar en el juego.

Como se mencionó anteriormente, el EDA puede variar según la persona, el clima y la hora del día principalmente, debido a esta situación se consideró una fase previa de siete minutos. Los primeros dos minutos se descartaron de los datos para evitar datos en los que se estabiliza la pulsera, los siguientes cinco minutos se utilizaron para que el participante se relajara, de manera que estos datos se pudieran utilizar como medida base.

Después de estos siete minutos previos se le presentó el video juego al participante en una iPad mini para hacer más natural la experiencia de juego. El participante juega las tres sesiones con distintas dificultades y al final de cada una de ellas se le muestra el SAM para que llene los datos de activación y valencia.

El videojuego se comunica con un servidor para la recolección de datos de puntuación y muertes del jugador, así como también las encuestas del SAM que este contestaba. Los datos de la pulsera e4 son enviados a la página de empática, donde se almacenan las sesiones y se puede obtener los datos.

Una vez obtenidos los datos los datos del SAM se utilizaron para etiquetar los datos de las señales y las del juego, después de reunirlos se procesaron utilizando un script en lenguaje Python para hacer el calculo de las características de las señales y utilizarlas en el clasificador.

5.5. Métricas

Además de las métricas utilizadas en la propuesta se tomo los valores de valencia y activación de la auto-evaluación realizada con el SAM por los participantes. Estos datos muestran si el experimento logro inducir la emoción deseada para poder etiquetar los datos y entrar el clasificador.

Para evaluar el clasificador se tomo la precisión de esté, esta medida se obtuvo a través de las funciones de la librería *scikit-learn*, la cuál al implementar un clasificador estadístico, en este caso el SVM y el QDA, también obtiene su porcentaje de precisión.

Se hizo un análisis de los datos del SAM para comprobar que las dificultades causaron el estado emocional deseado, en términos de valencia y excitación. Se hizo una comparación con una prueba t-Student para verificar que la valencia y excitación de las dificultades tuvieran una diferencia significativa entre ellas.

5.6. Resultados

Primero se obtuvo los resultados de la prueba t-Student que se muestran en las Tablas 11 y 12. Tabla 11 se muestra el valor p de la comparación de la valencia entre las distintas dificultades, de igual manera en la Tabla 12 se encuentra la comparación de la activación.

Tabla 11: **Comparación de valencia entre dificultades.** Valores p de la comparación para determinar la existencia de una diferencia significativa entre los valores de valencia . * $p < 0.05$. ** $p > 0.05$.

Dificultad	Difícil	Media	Fácil
Difícil	-		
Media	8.47E-08	-	
Fácil	0.573235 **	4.79E-08	-

Tabla 12: **Comparación de activación entre dificultades.** Valores p de la comparación para determinar la existencia de una diferencia significativa entre los valores de la activación. * $p < 0.05$.

Dificultad	Difícil	Media	Fácil
Difícil	-		
Media	0.020006	-	
Fácil	1.56E-10	0.000025	-

Como se puede observar en la Tabla 11 y la Tabla 12 los valores de valencia y activación muestran diferencia significativa ($p < 0.05$), la única relación que muestra lo contrario es la valencia entre difícil y fácil, sin embargo esto es correcto, ya que ambas son negativas en el modelo de Russell. A continuación se muestra en la Figura 7 los valores obtenidos de la valencia para cada dificultad y en la Figura 8 los obtenidos para la activación.

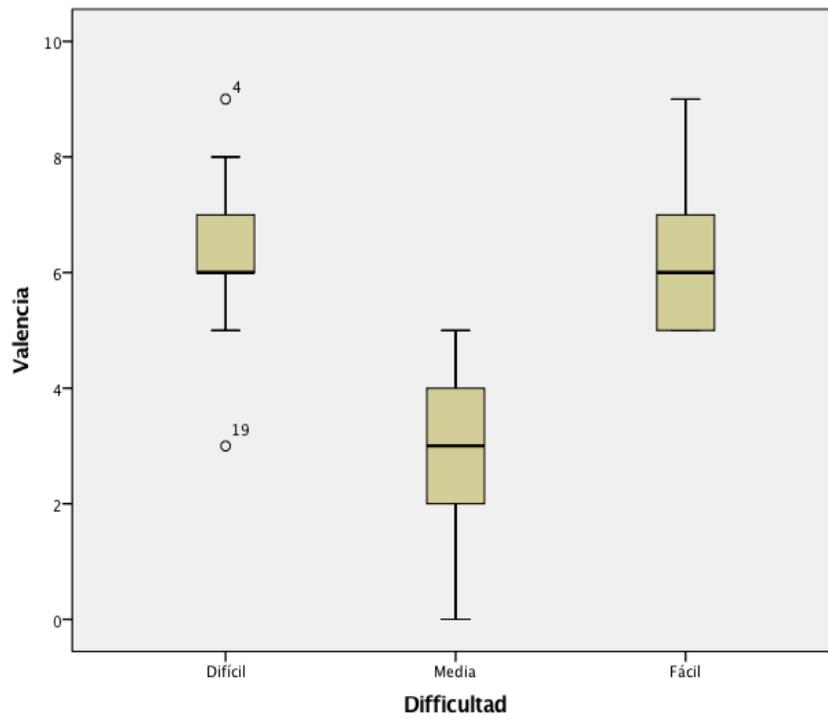


Figura 7: **Valencia en cada dificultad.** Rango de valores de valencia para cada dificultad.

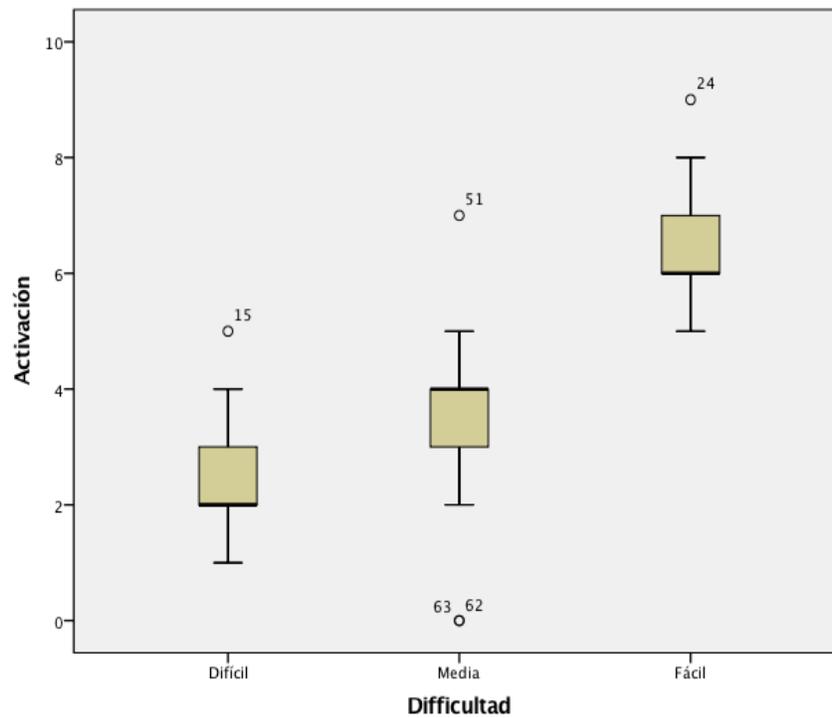


Figura 8: **Activación por dificultad.** Rango de valores de activación para cada dificultad.

Una vez comprobado que se obtuvieron los estados emocionales deseados se procesaron los datos para ser clasificados. Se hicieron distintas pruebas para verificar la efectividad de las distintas señales, en la Tabla 13 se muestra la precisión de los clasificadores utilizando las distintas señales por separado y en conjunto, además se analizó la precisión usando cada uno de los datos obtenidos del juego para encontrar la efectividad de estos.

Tabla 13: Resultados de clasificación del experimento. Precisión de los clasificadores SVM y QDA para las señales EDA, BVP, HR, SKT, datos del juego, así como el conjunto de las señales fisiológicas y el conjunto de las características utilizadas.

Clasificador	SVM		QDA	
	Valencia	Excitación	Valencia	Excitación
EDA	73%	64%	47%	52%
BVP	62%	69%	52%	54%
HR	63%	67%	54%	50%
SKT	52%	56%	52%	55%
Datos Juego	70%	77%	64%	61%
Puntuación	55%	61%	46%	68%
Mejor puntuación	70%	77%	55%	55%
Muertes	58%	54%	58%	51%
Señales sin datos del juego	66%	71%	58%	52%
Señales con datos del juego	77%	79%	65%	67%

Como se puede ver en la tabla la precisión del QDA es baja casi equivalente a tirar una moneda para predecir los valores, siendo el más alto 68% clasificando la activación por medio de la puntuación del juego. Los datos del SVM muestran mejores resultados, analizando las señales por separado se obtuvo mejor precisión con la EDA con un 73%, mientras que para la activación la de mayor

precisión fue el BVP con un 69%, para los datos del juego se identifica que el mejor indicador es la mejor puntuación obtenida, ya que esta logro un 70% para la valencia y un 77% para la activación. Utilizando todas las señales y los datos del juego se pudo obtener una precisión del 77% para valencia y un 79% para la activación, lo que afirma la hipótesis de que la fusión de características de conducta y de respuesta fisiológica ayudan a mejorar la precisión de clasificación, incluso los bajos resultados del QDA mejoraron al fusionar estos datos. En suma, el incluir datos de la interacción con el computador puede incrementar la precisión de los clasificadores entre un 7% a un 15%

6. Conclusión y Trabajos futuros

En este capítulo se concluye lo investigado en este trabajo, así como los trabajos a futuro que pueden mejorar o dar otra perspectiva a la propuesta.

6.1. Conclusión

En este trabajo se exploró la fusión de características de respuesta fisiológica y de la conducta para la clasificación de emociones, usando una pulsera comercial para la obtención de las señales fisiológicas. El experimento realizado mostro que el añadir las características de la conducta se puede mejorar la precisión de la clasificación de emociones.

Los resultados muestran una clasificación de emociones baja comparada a otros trabajos; sin embargo esta clasificación fue hecha en escala de valencia y activación, mientras que otras investigaciones clasifican solo unas cuantas emociones discretas. Otro factor que influye en la diferencia de precisión es la diferencia de calidad en los sensores utilizados, ya que, la mayoría de los trabajos investigados utilizan dispositivos de alta calidad.

Este incremento en la precisión abre la posibilidad del uso de pulseras comerciales como la pulsera e4, permitiendo la clasificación de emociones en entornos reales, a diferencia de otros trabajos que dependen de sensores caros.

El aporte de este trabajo alienta al uso de la detección de emociones para la mejora de software educativo y video juegos, permitiendo entender al usuario para poder brindar una experiencia de que permita la inmersión y el aprendizaje.

En conclusion la fusión de características de señal fisiológica y de conducta para la clasificación de emociones es una alternativa a los métodos actuales que mejora la precisión y permite el uso de una pulsera comercial para uso en entornos de la vida diaria.

6.2. Trabajos futuros

Este trabajo es un el inicio para la clasificación de emociones fusionando características de respuesta fisiológica y de conducta. Las distintas áreas que abarca este trabajo dan lugar a distintos trabajos futuros.

Dentro los trabajos futuros se puede explorar otras características no lineales para las señales obtenidas, como lo proponen (Valenza, Lanata, and Scilingo 2012). Estas características permitirían un mejor entendimiento del comportamiento de las señales como la del ritmo cardiaco.

Igualmente es posible explorar disintas características de conducta, tanto para videojuegos como para sistemas educativos, como aquellas sugeridas por (Baker et al. 2012) en sistemas educativos.

Distintos generos de video juegos causan distintos efectos en las personas, esto hace necesario que se estudie como afecta a la investigación otro tipo de video juegos.

Como uno de los objetivos es perseguir el uso de dispositivos comerciales que las personas puedan tener en casa, es necesario probar más dispositivos con sensores de bajo costo que se puedan adaptar y cuyas limitaciones no afecten la clasificación de emociones.

Investigar como las clasificaciones de baja / alta activación y baja / alta valencia afecta el rendimiento en juegos serios educativos, para en un futuro tener un control de ajuste de dificultad similar a las emociones con buenos resultados.

Bibliografía

- Agrafioti, Foteini, Dimitris Hatzinakos, and Adam K. Anderson. 2012. "ECG Pattern Analysis for Emotion Detection." *IEEE Transactions on Affective Computing* 3(1): 102–15.
- Ben Ammar, Mohamed, Mahmoud Neji, Adel M. Alimi, and Guy Gouardères. 2010. "The Affective Tutoring System." *Expert Systems with Applications* 37(4): 3013–23. <http://dx.doi.org/10.1016/j.eswa.2009.09.031>.
- Anagnostopoulos, Christos-Nikolaos, Theodoros Iliou, and Ioannis Giannoukos. 2012. "Features and Classifiers for Emotion Recognition from Speech: A Survey from 2000 to 2011." *Artificial Intelligence Review*. <http://link.springer.com/10.1007/s10462-012-9368-5> (November 14, 2014).
- Arroyo, Ivon et al. 2009. "Emotion Sensors Go to School." *Frontiers in Artificial Intelligence and Applications* 200(1): 17–24.
- Azevedo, Roger et al. 2016. "Interdisciplinary Research Methods Used to Investigate Emotions with Advanced Learning Technologies." In *Methodological Advances in Research on Emotion and Education*, Cham: Springer International Publishing, 231–43. <http://link.springer.com/10.1007/978-3-319-29049-2>.
- Baker, Ryan S.J.d. et al. 2012. "Towards Sensor-Free Affect Detection in Cognitive Tutor Algebra." *Proceedings of the 5th International Conference on Educational Data Mining*: 126–33. <http://eric.ed.gov/?id=ED537205>.
- Baker, Ryan S.J.d., Sidney K. D'Mello, Ma.Mercedes T. Rodrigo, and Arthur C. Graesser. 2010. "Better to Be Frustrated than Bored: The Incidence, Persistence, and Impact of Learners' Cognitive–affective States during Interactions with Three Different Computer-Based Learning Environments." *International Journal of Human-Computer Studies* 68(4): 223–41. <http://linkinghub.elsevier.com/retrieve/pii/S1071581909001797> (January 10, 2015).
- Barrett T., L.; Wager. 2006. "The Structure of Emotion Evidence From Neuroimaging Studies." *Current Directions in Psychological Science* 15(2): 79–83.
- Bradley, M, and Peter J Lang. 1994. "Measuring Emotion: The Self-Assessment Semantic Differential Manikin and the." *Journal of Behavior Therapy and Experimental Psychiatry* 25(1): 49–59. <http://www.sciencedirect.com/science/article/pii/0005791694900639>.
- Calvo, Rafael A, and Sidney D'Mello. 2010. "Affect Detection: An Interdisciplinary Review of

- Models, Methods, and Their Applications.” *IEEE Transactions on Affective Computing* 1(1): 18–37. <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5520655>.
- Chanel, Guillaume, Joep J.M. Kierkels, Mohammad Soleymani, and Thierry Pun. 2009. “Short-Term Emotion Assessment in a Recall Paradigm.” *International Journal of Human-Computer Studies* 67(8): 607–27. <http://linkinghub.elsevier.com/retrieve/pii/S1071581909000433>.
- Chanel, Guillaume, Cyril Rebetez, Mireille Bétrancourt, and Thierry Pun. 2011. “Emotion Assessment from Physiological Signals for Adaptation of Game Difficulty.” *IEEE Transactions on Systems, Man, and Cybernetics Part A: Systems and Humans* 41(6): 1052–63.
- Christy, Thomas. 2014. “Ludmila I. Kuncheva.” *GSTF Journal on Computing (JoC)* 3(4).
- Chung, Sungwon, and Jongpil Cheon. 2015. “Emotion and Multimedia Learning : An Investigation of the Effects of Valence and Arousal on Different Modalities in an Instructional Animation.” *Instructional Science* 43(5): 545–59.
- Csikszentmihalyi, Mihaly. 2014. 22 NAMTA Journal *Applications of Flow in Human Development and Education*. <http://link.springer.com/10.1007/978-94-017-9094-9>.
- D’Mello, Sidney, and Art Graesser. 2011. “The Half-Life of Cognitive-Affective States during Complex Learning.” *Cognition & Emotion* 25(7): 1299–1308. <http://www.tandfonline.com/doi/abs/10.1080/02699931.2011.613668>.
- D’Mello, Sidney K. et al. 2008. “Automatic Detection of Learner’s Affect from Conversational Cues.” *User Modeling and User-Adapted Interaction* 18(1–2): 45–80.
- Drachen, Anders, Lennart E. Nacke, Georgios Yannakakis, and Anja Lee Pedersen. 2010. “Correlation between Heart Rate, Electrodermal Activity and Player Experience in First-Person Shooter Games.” *Proceedings of the 5th ACM SIGGRAPH Symposium on Video Games - Sandbox ’10*: 49–54. <http://dl.acm.org/citation.cfm?id=1836143>.
- Eerola, T., and J. K. Vuoskoski. 2011. “A Comparison of the Discrete and Dimensional Models of Emotion in Music.” *Psychology of Music* 39(1): 18–49. <http://pom.sagepub.com/cgi/doi/10.1177/0305735610362821>.
- Ekman, Paul. 1992. “Are There Basic Emotions?”
- Figner, Bernd, and Ryan O. Murphy. 2010. “Using Skin Conductance in Judgment and Decision Making Research.” *A Handbook of Process Tracing Methods for Decision Research: A Critical Review and User’s Guide*: 163–84.
- Fisher, Carolanne, and Penelope Sanderson. 1996. “Exploratory Sequential Data Analysis: Exploring Continuous Observational Data.” *Interactions* 3: 25–34.

- Friedrichs, Thomas et al. 2015. "Simple Games - Complex Emotions: Automated Affect Detection Using Physiological Signals." In *Entertainment Computing*, , 375–82.
- Ghergulescu, Ioana, and Cristina Hava Muntean. 2012. "Measurement and Analysis of Learner's Motivation in Game-Based E-Learning." In *Assessment in Game-Based Learning*, New York, NY: Springer New York, 355–78. http://link.springer.com/10.1007/978-1-4614-3546-4_18.
- Guendil, Zied, Zied Lachiri, Choubeila Maaoui, and Alain Pruski. 2015. "Emotion Recognition from Physiological Signals Using Fusion of Wavelet Based Features." (*lcmic*): 3–8.
- Haag, Andreas, Silke Goronzy, Peter Schaich, and Jason Williams. 2004. "Emotion Recognition Using Bio-Sensors: First Steps towards an Automatic System." *Affective dialogue systems i*: 36–48.
- Hagerman, Inger et al. 1996. "Chaos-Related Deterministic Regulation of Heart Rate Variability in Time- and Frequency Domains: Effects of Autonomic Blockade and Exercise." *Cardiovascular Research* 31(3): 410–18.
- Hudlicka, E. 2008. "Affective Computing for Game Design." *4th International North-American Conference on Intelligent Games and Simulation, Game-On 'NA 2008*: 5–12. <http://www.scopus.com/inward/record.url?eid=2-s2.0-84898620373&partnerID=40&md5=63d1ba4b90b9cf6f5dc83903375c377b>.
- Jang, Eun-hye et al. 2013. "Classification of Human Emotions from Physiological Signals Using Machine Learning Algorithms: Recognition of Pain, Boredom, and Surprise Emotions." *ACHI 2013: The Sixth International Conference on Advances in Computer-Human Interactions (c)*: 395–400.
- Jang, Eun-Hye et al. 2015. "Analysis of Physiological Signals for Recognition of Boredom, Pain, and Surprise Emotions." *Journal of Physiological Anthropology* 34(1): 25. <http://www.jphysiolanthropol.com/content/34/1/25>.
- Jones, Christian, and Andrew Deeming. 2008. "Affective Human-Robotic Interaction." *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 4868 LNCS: 175–85.
- Katsis, Christos D., Nikolaos S. Katertsidis, and Dimitrios I. Fotiadis. 2011. "An Integrated System Based on Physiological Signals for the Assessment of Affective States in Patients with Anxiety Disorders." *Biomedical Signal Processing and Control* 6(3): 261–68. <http://dx.doi.org/10.1016/j.bspc.2010.12.001>.
- Kim, K H, S W Bang, and S R Kim. 2004. "Emotion Recognition System Using Short Term Monitoring of Physiological Signals." *Medical Biological Engineering and computing*

42(Journal Article): 419–27.

Laamarti, Fedwa, Mohamad Eid, Abdulmotaleb El Saddik, and Abdulmotaleb El Saddik. 2014. "Review Article An Overview of Serious Games." *International Journal of Computer Games Technology* 2014.

Leutner, Detlev. 2014. "Motivation and Emotion as Mediators in Multimedia Learning." *Learning and Instruction* 29: 174–75. <http://dx.doi.org/10.1016/j.learninstruc.2013.05.004>.

Li, Lan, and Ji-hua Chen. 2006. "Emotion Recognition Using Physiological Signals from Multiple Subjects." *2006 International Conference on Intelligent Information Hiding and Multimedia*: 355–58. <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4041736>.

Lisetti, C L, and F Nasoz. 2004. "Using Noninvasive Wearable Computers to Recognize Human Emotions from Physiological Signals." *Journal of Applied Signal Processing* 11: 1672–87.

Liu, C, K Conn, N Sarkar, and W Stone. 2008. "Physiology-Based Affect Recognition for Computer-Assisted Intervention of Children with Autism Spectrum Disorder." *International journal of human- ...* 66: 662–77. <http://www.sciencedirect.com/science/article/pii/S1071581908000487>.

Liu, Changchun, Pramila Agrawal, Nilanjan Sarkar, and Shuo Chen. 2009. "Dynamic Difficulty Adjustment in Computer Games Through Real-Time Anxiety-Based Affective Feedback." *International Journal of Human-Computer Interaction* 25(6): 506–29.

Mandryk, Regan L., and M. Stella Atkins. 2007. "A Fuzzy Physiological Approach for Continuously Modeling Emotion during Interaction with Play Technologies." *International Journal of Human Computer Studies* 65(4): 329–47.

McMahan, Timothy, Ian Parberry, and Thomas D. Parsons. 2015. "Modality Specific Assessment of Video Game Player's Experience Using the Emotiv." *Entertainment Computing* 7: 1–6. <http://dx.doi.org/10.1016/j.entcom.2015.03.001>.

Nogueira, Pedro A., Rui Rodrigues, and Eugénio Oliveira. 2013. "Real-Time Psychophysiological Emotional State Estimation in Digital Gameplay Scenarios." *Communications in Computer and Information Science* 383 CCIS(PART 1): 243–52.

Nogueira, Pedro A., Rui Rodrigues, Eugénio Oliveira, and Lennart E. Nacke. 2013. "A Hybrid Approach at Emotional State Detection: Merging Theoretical Models of Emotion with Data-Driven Statistical Classifiers." *Proceedings - 2013 IEEE/WIC/ACM International Conference on Intelligent Agent Technology, IAT 2013* 2: 253–60.

Núñez Castellar, Elena, Jan Van Looy, Arnaud Szmalec, and Lieven De Marez. 2014. "Improving Arithmetic Skills through Gameplay: Assessment of the Effectiveness of an Educational Game

- in Terms of Cognitive and Affective Learning Outcomes.” *Information Sciences* 264: 19–31.
- Öhman, Arne. 1987. “The Psychophysiology of Emotion: An Evolutionary-Cognitive Perspective.” *Advances in psychophysiology* 2(79): 127.
- Park, Min Woo, Chi Jung Kim, Mincheol Hwang, and Eui Chul Lee. 2013. “Individual Emotion Classification between Happiness and Sadness by Analyzing Photoplethysmography and Skin Temperature.” *2013 Fourth World Congress on Software Engineering*: 190–94. <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6754284>.
- Pekrun, Reinhard et al. 2011. “Measuring Emotions in Students’ Learning and Performance: The Achievement Emotions Questionnaire (AEQ).” *Contemporary Educational Psychology* 36(1): 36–48. <http://dx.doi.org/10.1016/j.cedpsych.2010.10.002>.
- Picard, Rosalind W. 1995. “Affective Computing.” *MIT press* (321): 1–16. <papers3://publication/uuid/9C02FCAE-FE2E-4D2C-9707-766804777DC9>.
- Posner, Jonathan, James A Russell, and Bradley S Peterson. 2005. “The Circumplex Model of Affect: An Integrative Approach to Affective Neuroscience, Cognitive Development, and Psychopathology.” *Development and Psychopathology* 17(3): 715–34.
- Rani, Pramila, Changchun Liu, Nilanjan Sarkar, and Eric Vanman. 2006. “An Empirical Study of Machine Learning Techniques for Affect Recognition in Human-Robot Interaction.” *Pattern Analysis and Applications* 9(1): 58–69.
- Russell, James a. 1980. “A Circumplex Model of Affect.” *Journal of Personality & Social Psychology* 39(6): 1161–78. <https://www2.bc.edu/~russeljm/publications/Russell1980.pdf>.
- Saarni, Carolyn. 1999. *The Development of Emotional Competence*. Guilford Press.
- Sabourin, J, B Mott, and Lester. J. 2011. “Modeling Learner Affect with Theoretically Grounded Dynamic Bayesian Networks .” *Proceedings of the Fourth International Conference on Affective Computing and Intelligent Interaction*: 286–95.
- Selvaraj, Jerritta, Murugappan Murugappan, Khairunizam Wan, and Sazali Yaacob. 2013. “Classification of Emotional States from Electrocardiogram Signals: A Non-Linear Approach Based on Hurst.” *Biomedical engineering online* 12(1): 44. <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3680185&tool=pmcentrez&rendertype=abstract>.
- Talarico, Jennifer M, Kevin S L A Bar, David C Rubin, and North Carolina. 2004. “Emotional Intensity Predicts Autobiographical Memory Experience.” 32(7): 1118–32.
- Valenza, Gaetano et al. 2014. “Revealing Real-Time Emotional Responses: A Personalized

- Assessment Based on Heartbeat Dynamics.” *Scientific reports* 4: 4998. <http://www.nature.com/srep/2014/140518/srep04998/full/srep04998.html>.
- Valenza, Gaetano, Paolo Allegrini, Antonio Lanatà, and Enzo Pasquale Scilingo. 2012. “Dominant Lyapunov Exponent and Approximate Entropy in Heart Rate Variability during Emotional Visual Elicitation.” *Frontiers in Neuroengineering* 5(February): 1–7.
- Valenza, Gaetano, Antonio Lanata, and Enzo Pasquale Scilingo. 2012. “The Role of Nonlinear Dynamics in Affective Valence and Arousal Recognition.” *IEEE Transactions on Affective Computing* 3(2): 237–49.
- Valstar, Michel F. et al. 2012. “Meta-Analysis of the First Facial Expression Recognition Challenge.” *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics* 42(4): 966–79.
- Vapnik, V. 1998. “Statistical Learning Theory Wiley New York Google Scholar.”
- Yang, Songfan, and Bir Bhanu. 2011. “Facial Expression Recognition Using Emotion Avatar Image.” *2011 IEEE International Conference on Automatic Face and Gesture Recognition and Workshops, FG 2011*: 866–71.
- Yannakakis, Georgios N, and John Hallam. 2007. “Entertainment Modeling in Physical Play through Physiology beyond Heart-Rate.” *ACII '07 Proceedings of the 2nd international conference on Affective Computing and Intelligent Interaction* 4738 LNCS(March): 254–65. <http://www.scopus.com/inward/record.url?eid=2-s2.0-38049093761&partnerID=40&md5=4f8d91bc203f0c9cb5f6988132ccd4b9>.
- Yoo, Sun K et al. 2005. “Using Heart Rate Variability and Skin Resistance.” *Proceedings of the First international conference on Advances in Natural Computation* 1: 818–24. <http://dl.acm.org/citation.cfm?id=2137448>.
- Yoon, Kwon Ha et al. 2015. “Analysis of Statistical Methods for Automatic Detection of Congestive Heart Failure and Atrial Fibrillation with Short RR Interval Time Series.” *2015 9th International Conference on Innovative Mobile and Internet Services in Ubiquitous Computing*: 452–57. <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7284993>.
- Zhao, Chunlin, Min Zhao, Jianpin Liu, and Chongxun Zheng. 2012. “Electroencephalogram and Electrocardiograph Assessment of Mental Fatigue in a Driving Simulator.” *Accident Analysis & Prevention* 45: 83–90. <http://linkinghub.elsevier.com/retrieve/pii/S0001457511003241>.

Anexos

Anexo A. Componentes principales para el análisis de las señales

Para analizar las señales y obtener sus características se utilizaron las siguientes herramientas:

- Python 2.7.11
- Spyder 2.3.8
- Numpy 1.10.4
- Scikit-learn 0.17.1
- Scipy 0.17.0

En la Figura 9 se muestra el proceso de análisis de las señales.

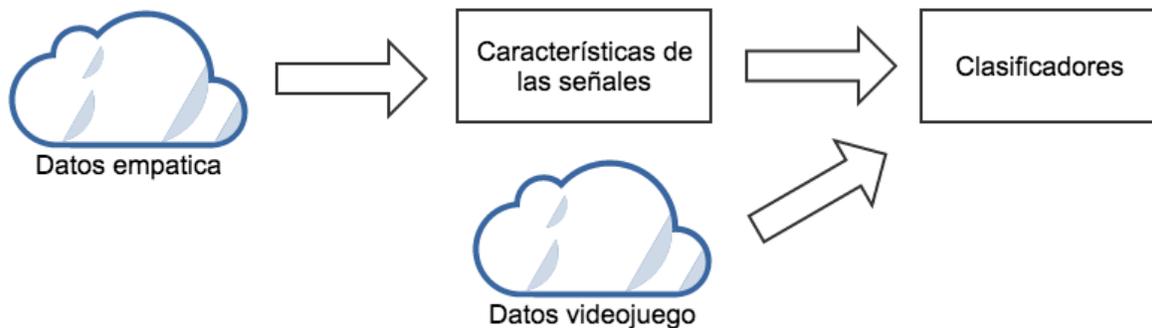


Figura 9: Proceso de análisis de las señales.

La obtención de características de las señales realiza una lectura de un archivo “csv” con los datos obtenidos de la pulsera Empatica e4. De acuerdo a las sesiones del experimento se divide la señal y usando funciones de las librerías numpy y scipy se obtienen las características.

La librería Scipy permite calcular la entropía de Shannon además de tener la capacidad de crear graficas de ser necesario para mostrar los datos, mientras que la librería numpy tiene diversas funciones para manejar arreglos de datos y

realizar cálculos lineales. En este trabajo la librería numpy sirvió para la lectura de archivos “csv”, así como el calculo de la media y desviación estándar de los datos.

Los datos obtenidos se juntan con los datos del videojuego y son clasificados usando la librería de scikit-learn como se muestra en las Figura 10 y Figura 11. Esta librería contiene funciones para el clasificador SVM y QDA, así como para obtener resultados de precisión con validación cruzada, segmentación de datos de prueba y entrenamiento aleatorios, entre otras funciones.

```
1. import numpy as np
2. from sklearn import svm
3. from sklearn.cross_validation import cross_val_predict, cross_val_score, train_test_split
4. from sklearn.discriminant_analysis import QuadraticDiscriminantAnalysis
5.
6. print("-----Lectura de datos-----")
7. #Toma los datos del archivo csv de las señales y el videojuego
8. datosT = np.loadtxt('Datos_Experimento.csv',delimiter=',',skiprows=1)
9.
10. print("-----clasificadores-----")
11.
12.
13. names = ["SVM RBF", "QDA"]
14. #Lista e inicializa los clasificadores a utilizar
15. classifiers = [
16.     svm.SVC(C=1, kernel="rbf"),
17.     QuadraticDiscriminantAnalysis()
18. ]
19. #Se define las características de salida, es dato informativo y visual
20. salidas = ["Diff", "Val", "Aro"]
21.
22. print("-----proceso datos-----")
23. #Se inicializa los arreglos que tendran los datos de las características
24. # y los arreglos con los datos de las salidas
25. x = []
26. y = []
27. p = []
28. q = []
29. #Se asignan los valores de las características correspondientes
30. for datos in datosT:
31.     #Los datos del 1 al 11, para las características de entrada
32.     x.append(datos[:11])
33.     #Los datos del 13,14 y 15 que son las salidas de dificultad, valencia y
    activación
34.     y.append(datos[13])
35.     p.append(datos[14])
36.     q.append(datos[15])
37. #Los arreglos se transforman a arreglos del numpy
38. x = np.array(x)
39. y = np.array(y)
40. p = np.array(p)
41. q = np.array(q)
42. #Se indica que arreglos son las salidas
43. targets = {salidas[0]:y, salidas[1]:p, salidas[2]:q}
```

Figura 10: **Clasificadores (parte 1)**. Código para la lectura de archivo csv con los datos del experimento, partición aleatoria y validación cruzada utilizando los clasificadores SVM y QDA.

```

44. print("-----prediccion-----")
45. #Para cada salida se utiliza cada clasificador
46. for salida in salidas:
47.     for name, clf in zip(names,classifiers):
48.         #Ejecuta las siguientes instrucciones para cada clasificador
49.
50.         print("-----clasificador "+name+" para "+salida+"-----")
51.         #Parte los datos en prueba y entrenamiento de forma aleatoria
52.         x_train, x_test, y_train, y_test = train_test_split(x, targets[salida],
                    test_size=.2)
53.
54.         print("-----Presicion validacion cruzada-----")
55.         for score in cross_val_score(clf, x_test, y_test, cv=10):
56.             print('%0.2f' % score).rstrip('0'))

```

Figura 11: **Clasificadores (parte 2)**. Código para la lectura de archivo svb con los datos del experimento, partición aleatoria y validación cruzada utilizando los clasificadores SVM y QDA.

Agradecimientos

Agradezco al Centro de Investigación en Matemáticas CIMAT y al Consejo Nacional de Ciencia y Tecnología CONACYT, por la oportunidad y los apoyos para estudiar la maestría.

También expresar mi agradecimiento al Dr. Carlos Alberto Lara Álvarez por su compromiso y guía para el desarrollo de esta tesis.

Finalmente agradecer a mi familia por su ayuda y apoyo en el transcurso de la maestría.



CENTRO DE INVESTIGACIÓN EN MATEMÁTICAS, A.C.

BIBLIOTECA

AUTORIZACION
PUBLICACION EN FORMATO ELECTRONICO DE TESIS

El que suscribe
Autor(s) de la tesis: Luis Salvador López Hernández

Título de la tesis: Clasificación de emociones fusionando características de análisis de respuesta fisiológica y análisis automatizado de conducta en video juegos.

Institución y Lugar: Centro de Investigación en Matemáticas, CIMAT, Zacatecas.

Grado Académico: Licenciatura () Maestría (X) Doctorado () Otro () -----
2017

Año de presentación: Ingeniería de Software

Área de Especialidad: Dr. Carlos Alberto Lara Álvarez, Dr. Hugo Arnoldo Mitre Hernández

Director(es) de Tesis: drstein.rexxar@gmail.com

Correo electrónico: Priv. Los Frenos # 104-C col. Fuentes del Bosque

Domicilio: Zacatecas, Zac, C. P. 98067

Palabra(s) Clave(s): Clasificación de emociones, señales fisiológicas, análisis de conducta, video juegos.

Por medio del presente documento autorizo en forma gratuita a que la Tesis arriba citada sea divulgada y reproducida para publicarla mediante almacenamiento electrónico que permita acceso al público a leerla y conocerla visualmente, así como a comunicarla públicamente en la Página WEB del CIMAT.

La vigencia de la presente autorización es por un periodo de 3 años a partir de la firma de presente instrumento, quedando en el entendido de que dicho plazo podrá prorrogar automáticamente por periodos iguales, si durante dicho tiempo no se revoca la autorización por escrito con acuse de recibo de parte de alguna autoridad del CIMAT

La única contraprestación que condiciona la presente autorización es la del reconocimiento del nombre del autor en la publicación que se haga de la misma.

Atentamente

Nombre y firma del tesista