

Reconocimiento de niveles de ansiedad a partir del análisis multimodal y técnicas de aprendizaje de máquina en señales fisiológicas.

Carlos Alberto Gutiérrez Gómez

Director

Alvaro Angel Orozco Gutiérrez



Universidad Tecnológica de Pereira
Facultad de Ingeniería Eléctrica, Electrónica, Física y Ciencias de la
Computación
Maestría en Ingeniería Eléctrica
Grupo de investigación en Automática
Pereira-Risaralda
2014

Índice general

I. Introducción	5
1. Justificación	6
1.1. Pertinencia	6
1.2. Viabilidad	6
1.3. Impacto	7
2. Planteamiento del problema	8
2.1. Descripción	8
2.2. Formulación del problema de Investigación	9
3. Objetivos	10
3.1. General	10
3.2. Específicos	10
II. Antecedentes Bibliográficos	11
4. Preliminares fisiológicos	12
4.1. Definición de Emoción	12
4.1.1. Funciones de las emociones	12
4.1.2. Bases neurobiológicas de la emoción	13
4.2. Ansiedad	14
4.3. Metodología para el análisis y reconocimiento de estados emocionales	15
4.4. Señales Fisiológicas	16
4.4.1. La frecuencia cardíaca	16
4.4.2. La respuesta galvánica de piel	16
4.4.3. La frecuencia respiratoria	17
4.4.4. Señales Electroencefalograficas (EEG)	17
4.4.5. Señales Electromiográficas (EMG)	18
5. Marco Conceptual	19
5.1. Transformada wavelet discreta.	19
5.2. Análisis Multi-resolución	20
5.3. Esquema adaptativo de actualización dual	20
5.4. Métricas Estadísticas	21

5.5. Clasificador de k vecinos más cercanos (k-nn k-Nearest Neighbors)	22
5.6. Clasificador Bayesiano	22
5.7. Máquinas de soporte vectorial	23
5.8. Clasificador por Procesos Gaussianos	23
III. Materiales y Métodos	25
6. Materiales y Metodos	26
6.1. Materiales	26
6.1.1. Base de Datos DEAP	26
6.1.2. Caja de Herramientas	26
6.2. Metodología	27
IV. Resultados y Discusión	29
7. Resultados y Discusión	30
7.1. Resultados	30
7.1.1. Caracterización con ventana usando Transformada Wavelet Discreta	30
7.1.2. Caracterización con ventana usando Wavelet Adaptativa	31
7.2. Discusión General	32
V. Conclusiones	34
8. Conclusiones	35
Bibliografía	36

Resumen

Aunque en la actualidad, los sistemas de reconocimiento de niveles de ansiedad son ampliamente utilizados en la fase de terapia cognitiva conductual, interfaz hombre computador, técnicas de manejo afectivas, las técnicas de procesamiento desarrolladas aun no alcanzan porcentajes de acierto altos, debido a problemas presentes en las mismas señales, como pueden ser los procesos de filtrado, artefactos, sistemas de caracterización que no determinan a ciencia cierta el contenido emocional presente en dichas señales ó sistemas de clasificación que no realizan en forma óptima su tarea.

De igual forma se describe la idea fundamental de cada una de las técnicas con sus pro y sus contra, con el fin de establecer un marco comparativo y de esta forma encontrar una combinación de técnicas que ofrezcan el mínimo de error en el reconocimiento de la emoción presente procedente de una señal fisiológica. Con base en los problemas que presentan los sistemas de reconocimiento de emociones, se requiere de un sistema capaz de realizar esta tarea de manera robusta que aplique técnicas que sean capaces de cuantificar la información presente en las diferentes señales fisiológicas estudiadas.

Por tanto se propone el desarrollo de una metodología para el reconocimiento de estados de ansiedad, mediante un análisis multimodal y técnicas de aprendizaje de maquina en señales fisiológicas con el fin de aplicar esta metodología en el tratamiento psicológico para el control de la ansiedad.

Abstract

Although in the present systems of emotion recognition are widely used in the phase of cognitive behavioral therapy, computer human interface, techniques of emotional management, the techniques developed processing even not reach percentages higher confidence due to problems at the same signals, such as filtering processes, devices, systems characterization not determine with certainty the emotional content present in these signals or classification systems that do not perform optimally in their task.

Likewise the fundamental idea of each of the techniques with their pros and cons, in order to establish a comparison frame and thus to find a combination of techniques which offer the least error in recognizing emotion described present from a physiological signal. Based on the problems presented by the emotion recognition systems, requires a system capable of performing this task robustly implement techniques that are able to quantify the information in the different physiological signals studied.

Therefore a methodology for the recognition of anxiety states proposed by multimodal analysis techniques and machine learning in physiological signals in order to apply this methodology in psychological treatment for anxiety management.

Agradecimientos

A mi director Dr. Alvaro Angel Orozco, por toda su dedicación y atención.

A los integrantes Hernán Dario Vargas y Heráan Felipe García del grupo de Automática de la Universidad Tecnológica de Pereira por su colaboración.

A mis Padres. y a DIOS.

Parte I.

Introducción

1. Justificación

1.1. Pertinencia

Para reconocer el nivel de ansiedad que experimenta una persona al ser tratada mediante terapias cognitivas conductuales, a través de respuestas fisiológicas que pueden ser medibles por sus señales fisiológicas, las cuales mediante un estudio adecuado de procesamiento de señales, accede a ser una descripción de su estado emocional. El reconocimiento de niveles de ansiedad a partir de señales fisiológicas, permitirá un adecuado tratamiento psicológico a la persona, mediante terapias cognitivas conductuales de acuerdo al estado de esta [1].

El reconocimiento de emociones en niveles de ansiedad es un tema que en la actualidad se viene desarrollando ampliamente, en el campo de la ingeniería utilizando el análisis de una señal o varias señales, lo que se conoce con el nombre de análisis multimodal, este relaciona la información desde diferentes fuentes para posteriormente maximizar la capacidad de información y así discriminar de manera eficiente el nivel de ansiedad de la persona [2], [3]

La importancia que ha suscitado el estudio de estados emocionales para el reconocimiento de estados de ansiedad en los últimos años, ha hecho posible la implementación de modelos que permitan analizar características mediante métodos ya sean clínicos, psicológicos o computacionales [1]. Pese a grandes aportes realizados desde estas perspectivas se encuentran una serie de problemáticas que no permiten un gran desempeño de estos modelos. Los métodos de detección y procesamiento de estas características, se encuentran continuamente en proceso de evaluación ya que los resultados obtenidos no alcanzan el límite de confianza esperado [4].

Por lo tanto desde la ingeniería es importante conocer el comportamiento estadístico de una serie de señales fisiológicas como son la frecuencia cardíaca, la frecuencia respiratoria, la conductividad en la piel, electrocardiogramas, electromiogramas entre otras y realizar una correlación entre ellas. El conocimiento de la observación de los estados emocionales y específicamente el de ansiedad que mediante un análisis estadístico riguroso, y la implementación de los algoritmos de caracterización e identificación de estados emocionales, podrán dar un aporte significativo a los resultados obtenidos anteriormente. Por ello resulta de gran importancia el desarrollo de técnicas de procesamiento digital de señales para la detección de características por medio de procedimientos estadísticos [5] .

1.2. Viabilidad

Existen técnicas y bases de datos como herramientas primordiales para el reconocimiento de niveles de ansiedad en los cuales grupos de investigación desarrollan metodologías que permitan aplicar técnicas en el

reconocimiento de niveles de ansiedad a partir de procesamiento de señales fisiológicas en el plano emocional en la dimensión arousal, lo cual se puede evidenciar en trabajos realizados por grupos de investigación como la UniMAP, donde se basan en un método para evaluar los estados de estrés emocional de un individuo empleando señales SGR,EOG,ECG [6].

La Universidad de Angers cuyo trabajo de investigación tiene como objetivo identificar las emociones a través del habla o las expresiones faciales empleando señales EEG,EOG,ECG [2].

En [7], presentan la identificación de un clasificador de emociones óptimo, con selecciones de características, utilizando señales fisiológicas, las cuales son analizadas para extraer características para el patrón de datos emocionales. Estas señales son: temperatura de la piel (SKT) , fotopleletismografía (PPG) , la actividad electrodérmica (EDA) y un electrocardiograma (ECG), que son inducidas por estímulos emocionales como son: la alegría , tristeza , ira, miedo , asco, sorpresa , y estrés.

1.3. Impacto

Se pretende desarrollar una metodología que sirva como coadyudante a las terapias cognitivas conductuales o sea que a partir de la medición de los niveles de ansiedad mediante el análisis multimodal de señales fisiológicas le permita al especialista determinar el estado del paciente en una determinada terapia.

2. Planteamiento del problema

2.1. Descripción

En el campo de la Psicología la forma más fácil de reconocer el nivel de ansiedad de una persona es por medio de terapias cognitivas conductuales, que lleven al paciente a manifestar su estado emocional [4]. Desde la ingeniería en los últimos tiempos, se han venido utilizando para el reconocimiento de niveles de ansiedad, diferentes tipos de señales fisiológicas, las cuales aportan una cantidad de características relevantes para la detección de emociones en un paciente [8].

Los niveles de ansiedad resultan de la suma de las respuestas fisiológicas y conductuales ante los eventos externos o internos que activan el sistema cerebral, provocando cambios corporales [9](expresión facial, cambio de postura, variación del tono de la voz, sudoración aumento del ritmo cardiaco, la frecuencia respiratoria entre otros) [10]. Debido a su naturaleza, los niveles de ansiedad sirven para intuir acerca del estado interno del sujeto que las experimenta y poder actuar en consecuencia [11]. Para poder estudiar de forma experimental el procesamiento de niveles de ansiedad, se requiere de estímulos que sean capaces de evocar de manera confiable los distintos elementos de las emociones, es decir, tanto los sentimientos como las reacciones conductuales y fisiológicas [3]. Los estímulos afectivos que más se han empleado con esta finalidad han sido las palabras, los sonidos y las fotografías [12], aunque ocasionalmente también se han empleado olores, videos y música.

Las reacciones del individuo ante un estímulo o evento de ansiedad se pueden estudiar a través de un triple sistema de respuestas (conductuales, cognitivas y fisiológicas) [1] que contiene los componentes específicos de la emoción, como son la experiencia subjetiva, la apreciación cognitiva, la activación fisiológica y la conducta [13]. Todos estos aspectos son susceptibles de ser analizados durante la terapia psicológica del manejo de ansiedad, ya que el paciente es expuesto a situaciones controladas donde se busca que experimente diversas emociones que son la clave para la identificación de la patología a tratar y de su evolución durante el tratamiento.

Algunos enfoques previos se evidencian en trabajos realizados por grupos de investigación como la UniMAP, donde se basan en la medición de la frecuencia cardiaca para evaluar los estados de estrés emocional de un individuo [6]. También en [2] identifican las emociones a través del habla o las expresiones faciales empleando señales EEG, EOG, ECG. Otros trabajos como [14] presentan un enfoque multimodal para el reconocimiento de las emociones (señales fisiológicas, las expresiones faciales, el lenguaje, etc.), en el cual emplean una representación algebraica de los estados emocionales utilizando vectores multidimensionales. En [4], se propone un sistema para el reconocimiento de emociones a partir de señales fisiológicas, en el cual se realiza una fuerte discusión entre el proceso cognitivo, las emociones y como un humano se afecta fisiológicamente cuando experimenta cada emoción. Para ello, los autores utilizaron algoritmos de clasificación como el k-vecino más cercano (KNN), Análisis discriminante de funciones (DFA), y redes neuronales.

Si bien, en estos trabajos se emplean metodologías estructuradas para el reconocimiento de emociones y muestran importantes avances experimentales, aún no se han realizado investigaciones que se dediquen ex-

clusivamente al reconocimiento de la ansiedad. Además, estos enfoques no establecen cuál es la mejor forma de caracterizar las señales y tampoco es claro si los procedimientos se deben realizar con un sólo tipo de señal o varias señales simultáneas. En este trabajo se propone el reconocimiento de niveles de ansiedad (alto, neutro, bajo) en la escala arousal [15]. La metodología propuesta se basa en la transformación tiempo-escala de diversas señales fisiológicas multimodales: Electroencefalograma (EEG), frecuencia respiratoria, Pletismógrafo, temperatura, conductividad de piel (SGR), señales de electrocardiografía (ECG), señales de electrooculografía (EOG) y señales de electromiografía (EMG). Específicamente se emplea análisis multiresolución (transformada Wavelet discreta) y wavelets adaptativas. Luego se caracteriza sobre los coeficientes de representación usando descriptores estadísticos. Para validar los métodos propuestos se utilizan máquinas de aprendizaje supervisadas para el reconocimiento de 2 y 3 clases de niveles de ansiedad en la base de datos DEAP [10].

2.2. Formulación del problema de Investigación

Debido a los niveles de ansiedad que puede presentar un paciente, la automatización del proceso de identificación de estos, implica la combinación de análisis de señales provenientes de múltiples fuentes. Cuando las señales analizadas corresponden a variables fisiológicas tales como la frecuencia respiratoria, la frecuencia cardíaca, la conductividad de la piel, EEG, EOG, EMG, entre otras, no existe un consenso acerca de la forma en la cual se realiza el procedimiento de segmentación de las señales. En el desarrollo de los sistemas, la aplicación juega uno de los roles más importantes a la hora del diseño. En este trabajo se realizará un estudio del cual se derivará una metodología para la estimación del segmento de señal efectivo, y los métodos que caractericen de mejor forma los estados emocionales durante la terapia de manejo de ansiedad.

Los alcances de este trabajo incluyen algoritmos de caracterización y clasificación a partir del análisis multimodal de señales fisiológicas, esto debido a que los resultados derivados de este trabajo deben ser acoplados a herramientas que se están desarrollando actualmente dentro del grupo de investigación en automática de la Universidad Tecnológica de Pereira. *Las herramientas desarrolladas deben ser lo más transparente posibles a la terapia del manejo de ansiedad, para que de ninguna manera, la aplicación de los nuevos procedimientos condicione los resultados.*

¿El análisis multimodal de señales fisiológicas? conduce a una metodología eficaz en el reconocimiento de niveles de ansiedad?

3. Objetivos

3.1. General

Desarrollar una metodología de reconocimiento de niveles de ansiedad basado en el análisis multimodal y técnicas de aprendizaje de maquina en señales fisiológicas

3.2. Específicos

- Desarrollar una metodología de caracterización de señales fisiológicas basada en transformada Wavelet discreta y adaptativa
- Desarrollar algoritmos para el reconocimiento automático de niveles de ansiedad basado en entrenamiento de máquinas de aprendizaje: Clasificador bayesiano, Máquinas de soporte Vectorial y Procesos Gaussianos
- Validar los resultados de la metodología implementada en bases de datos reconocidas en el estado del arte.

Parte II.

Antecedentes Bibliográficos

4. Preliminares fisiológicos

4.1. Definición de Emoción

A menudo, las personas manifiestan estar emocionadas, o que se encuentran sentimentales, o que en ese momento no están con ánimos de hacer nada y no saben por qué, de igual forma, expresan tener cierto afecto por alguien o algo. Aunque suelen utilizarse de manera indistinta las palabras sentimientos, estado de ánimo y afecto, es pertinente preguntarse si en realidad son lo mismo o si existe alguna diferencia entre ellos. La respuesta es que estos conceptos no son lo mismo, aunque todos ellos surgen de las emociones. Por lo tanto, es pertinente definir estos términos bajo la perspectiva de la psicobiología.

Las emociones son un conjunto complejo de respuestas fisiológicas y conductuales, generalmente de corta duración, ante ciertos eventos externos o internos que dependen de la activación de ciertos sistemas cerebrales [16]. Dichas respuestas motivan conductas de aproximación o alejamiento que posibilitan la sobrevivencia del organismo ante determinadas situaciones. Provocando cambios corporales (expresiones faciales, postura, tono de la voz, entre otros) que sirven a los otros para intuir acerca de los estados internos del sujeto que experimenta las emociones y poder actuar en consecuencia [17].

A diferencia de las emociones, el estado de ánimo son emociones que se producen durante largos periodos de tiempo (horas, días, meses) y no necesariamente dependen de estímulos externos. Por último, el afecto es el producto de la interacción dentro de un contexto social y nos permite tener una relación con otras personas (o algún objeto) a quién se le tiene cariño, simpatía o resentimiento [18].

Podría decirse que el proceso de producción de una emoción implica [16]:

1. Inducción de la emoción (percepción y evaluación de un estímulo significativo).
2. Generación de cambios en el cuerpo y el cerebro.
3. Patrones neurales que representan los cambios orgánicos.
4. Sensación de estos patrones neurales en forma de imágenes (sentimientos).
5. Sentimientos de los sentimientos (lo cual es parte de un proceso consciente).

Considerando lo anterior, se pueden identificar cuatro elementos en las emociones: perceptivo, subjetivo, conductual, expresivo y fisiológico.

4.1.1. Funciones de las emociones

Desde la época de Darwin se ha planteado que las emociones son funcionales, es decir, facilitan la adaptación de los individuos a su entorno, ya que preparan al organismo para tener acciones rápidas y le dan

flexibilidad a las acciones. Se ha sugerido que las emociones son el sistema motivacional primario, es decir, lo que mueve y orienta todos nuestros actos [19]. De acuerdo con esta teoría, se considera que las emociones están organizadas alrededor de dos sistemas motivacionales cerebrales, el apetitivo y el aversivo. El primer sistema hace referencia a conductas de aproximación hacia estímulos placenteros o positivos, mientras que el sistema aversivo produce conductas de evitación o huida ante estímulos negativos o potencialmente peligrosos [20]. De esta manera, si entendemos a las emociones orientadas a un objeto como disposiciones a la acción, entonces el sistema motivacional apetitivo se activará para hacer posible la aproximación a una potencial pareja sexual y tener interacción sexual, provocando afectos como la alegría y el entusiasmo. En cambio cuando nuestras vidas están en peligro, el sistema aversivo permite al individuo evitar o huir de situaciones o estímulos peligrosos y generar ciertas formas de afecto negativo, como el miedo o el asco [21]. El nivel de activación (o arousal) que acompaña al evento emocional, modulará la fuerza con que estos dos sistemas respondan al medio ambiente [22].

Para [23] la conducta emocional, junto con todos los cambios fisiológicos que conlleva, es fundamental para la supervivencia, teniendo ocho propósitos distintos: protección, destrucción, reproducción, reintegración, afiliación, rechazo, exploración y orientación. Las emociones son indispensables para el comportamiento social, ya que su expresión y percepción posibilitan la comunicación de los estados afectivos, regulan la manera en que los seres humanos responden entre sí, facilitan las interacciones sociales y promueven la conducta prosocial [24]. Por otra parte, los sentimientos podrían ser el cimiento del comportamiento ético.

4.1.2. Bases neurobiológicas de la emoción

La mayoría de las investigaciones acerca de las bases biológicas y fisiológicas de las emociones [25] se han centrado en el estudio del miedo, quizá porque la supervivencia depende de respuestas que permiten evitar una situación peligrosa. En [26] se describe un circuito cerebral asociado al miedo en ratas. Aunque estudios en humanos han confirmado estos hallazgos [27], se ha sugerido que en este circuito existen dos rutas diferentes: una subcortical que es rápida, burda e inconsciente y una cortical más lenta, pero a la vez más detallada y consciente. Los estímulos sensoriales llegan al tálamo, que envía información tanto a la ruta subcortical como a la cortical. En la ruta subcortical, un estímulo amenazante procedente del sistema visual o auditivo llega al tálamo, que a su vez envía información a la amígdala, pieza clave de la compleja maquinaria emocional. Esta estructura funge como un sistema de alarma capaz de activar todo el cerebro con la finalidad de optimizar el procesamiento sensorial y perceptual de los estímulos; permite la asociación entre estímulos y emociones, y participa en el reconocimiento de las emociones de los otros. A este respecto, se ha descubierto que la amígdala contiene neuronas que responden selectivamente a la identidad facial, a algunas emociones faciales y durante la interacción social [28].

Para poder estudiar de forma experimental el procesamiento emocional se requiere de estímulos que sean capaces de evocar de manera confiable los distintos elementos de las emociones, es decir, tanto los sentimientos como las reacciones conductuales y fisiológicas, lo cual a veces no es fácil de lograr en el laboratorio. Los estímulos afectivos que más se han empleado con esta finalidad han sido las expresiones faciales [29], las palabras, los sonidos [30] y las fotografías [31], aunque ocasionalmente también se han empleado olores [32, 33], videos [34] y música [35].

Las reacciones del individuo ante un estímulo o evento emocional se pueden estudiar a través de un triple sistema de respuestas (conductuales, cognitivas y fisiológicas) que contiene los componentes específicos de la emoción, como son la experiencia subjetiva, la apreciación cognitiva, la activación fisiológica y la conducta [36]. La activación fisiológica involucra tres tipos de respuestas: autónomas, somáticas y centrales.

4.2. Ansiedad

La ansiedad es una manifestación afectiva [37]. Se trata de una experiencia interna, que se puede calificar como emoción. La ansiedad es un mecanismo humano de adaptación al medio y ayuda a superar ciertas exigencias del diario vivir. En este orden de ideas, se puede considerar la ansiedad como una defensa que entra en estado de alerta, frente a estímulos que rompen el equilibrio fisiológico y psicológico. La ansiedad se puede observar desde tres posiciones: la ansiedad positiva se vivencia con lo cotidiano y entra de lleno en el campo de la motivación que nos hace alcanzar metas. La ansiedad normal y proporcionada, así como sus manifestaciones, no pueden ni deben eliminarse, dado que se trata de un mecanismo funcional y adaptativo. Se trata de saber convivir con la ansiedad, sin perder la operatividad. La ansiedad negativa se caracteriza por sentimientos de malestar, preocupación, hipervigilancia, tensión, temor, inseguridad, sensación de pérdida de control, percepción de fuertes cambios fisiológicos. Estos cambios fisiológicos son consecuencia de la activación del sistema nervioso, del sistema endocrino y del sistema inmunológico. Por lo general solo percibimos algunos de los desordenes persistentes que provoca esta activación desadaptativa. La persistencia de estos cambios puede acarrear una serie de desordenes psicofisiológicos transitorios, como dolores de cabeza, insomnio, disfunción eréctil, anorgasmia femenina, contracturas musculares, disfunciones gástricas, etc. A nivel de nuestro sistema motor la ansiedad se manifiesta con inquietud motora, hiperactividad, movimientos repetitivos, dificultades de comunicación consumo de sustancias, llanto, tensión en la expresión facial, etc. Es entonces cuando la ansiedad se convierte en un problema de salud. Desde la perspectiva dimensional del estudio de la emoción, se propone la existencia de dos dimensiones fundamentales a partir de las cuales puede explicarse toda la gama de emociones humanas. La primera dimensión es la valencia, cuyo rango comprende desde lo agradable a lo desagradable. La segunda dimensión es la activación, que se extiende desde la calma hasta la excitación [38] también se puede entender como "el grado con el cual un individuo se siente emocionado o excitado con lo que uno está haciendo" [15]. El arousal está muy relacionado con los estados de motivación "paratéticos", los cuales se pueden definir de la siguiente forma En el estado tético, un individuo está motivado por una meta u objetivo concreto. En el modo paratético, el individuo está motivado en primera instancia por la actividad en sí misma motivación intrínseca. Hedónico es que procura el placer o se relaciona con él. En la figura (4.1), se pueden observar la relación entre el arousal y los estados de motivación.

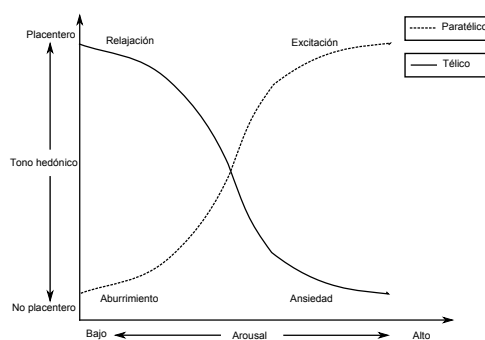


Figura 4.1.: Relación entre estado tético paratético, tono hedónico y nivel de arousal [39]

4.3. Metodología para el análisis y reconocimiento de estados emocionales

La psicofisiología se define como el estudio científico de la biología de la conducta y de los procesos psicológicos. Una de sus ramas es la psicofisiología instrumental, campo donde la ingeniería biomédica hace sus aportes principalmente en el desarrollo de interfaces biométricas con las cuales es posible adquirir información fiable para poder analizar el comportamiento de las distintas variables medidas. El desarrollo de sistemas cuyo objetivo es el de brindar un soporte en distintos procedimientos psicoclínicos sigue una metodología que abarca etapas dentro de las que se destacan la identificación de sectores relevantes de la señal biológica, procedimientos experimentales para medición de estados emocionales, determinación de umbrales, establecimiento de protocolos, validación estadística entre otros.

La mayoría de interfaces biométricas con base en tecnologías neurológicas, fundamentan su desarrollo desde la perspectiva de sistema [40]. Un sistema de asistencia completa según lo descrito en [41], incluye un transductor biométrico, una interfaz de control, y un dispositivo de aplicación o de asistencia, vinculados a través del controlador de dispositivo. Las Figuras 4.2 y 4.3 ilustran los componentes de un sistema de asistencia completo que también puede ser usado para representar las componentes de un sistema de interfaz biométrica completo. La parte del sistema que realiza la adquisición de la señal y el filtrado se llama transductor. El transductor emite un nivel lógico legible, para que la señal pueda ser interpretada por la máquina y de esta manera el sistema pueda comunicarse con la interfaz de control.

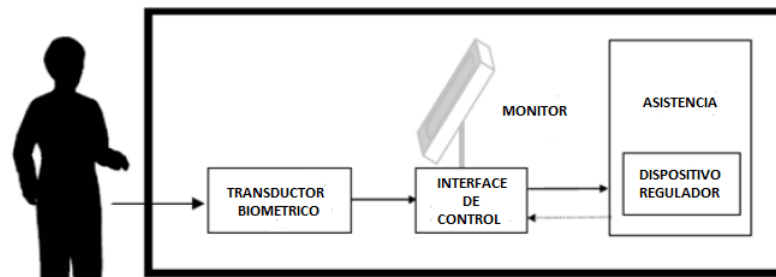


Figura 4.2.: Modelo de un Sistema de iterfáz biométrica [42, 43]

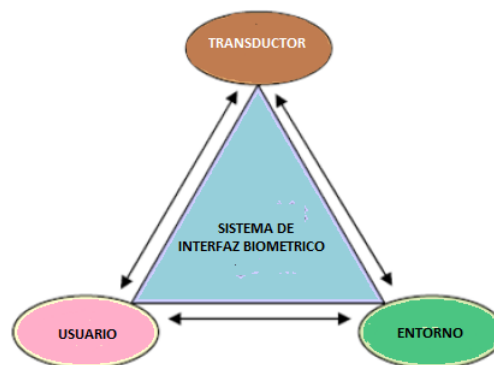


Figura 4.3.: Componentes del diseño de la interfaz del sistema biométrico

El estudio del reconocimiento emocional y de como embeberlo en una interfaz automatizada es de gran importancia en el campo de la psicología [44], pues el reconocimiento realizado por los interlocutores (también conocido por empatía) es la base de las relaciones humanas, y se fundamenta en la interpretación de las señales transmitidas de forma inconsciente y que no siempre son verbales. Es debido a esto que un buen sistema de reconocimiento debería llevar a cabo un análisis multimodal donde interviniera la información procedente de diferentes sensores.

En la actualidad el uso de sensores no invasivos para la detección de parámetros fisiológicos humanos es cada vez más importante y de mucha aplicación en temas de investigación científico-tecnológicos. A continuación se describen algunos de las investigaciones realizadas en el área del reconocimiento emocional, las cuales en su mayoría se enfocan en el análisis del comportamiento de la señales fisiológicas para poder observar estados emocionales en una persona.

4.4. Señales Fisiológicas

4.4.1. La frecuencia cardíaca

Es la respuesta autónoma que más varía en función a los contenidos emocionales de estímulos o situaciones, es decir, con la dimensión de valencia. La actividad eléctrica que se esparce en el músculo del corazón se registra a través de la técnica psicofisiológica llamada electrocardiograma (ECG), para lo cual se requiere de electrodos sobre la superficie de la piel del tórax. Por otra parte mediante la colocación de un pletismógrafo se mide el cambio en el volumen sanguíneo en el brazo, pierna o dedo, o aún en el cuerpo. Al observar un estímulo emocional, la frecuencia cardíaca presenta un patrón de respuesta trifásica, con una desaceleración inicial (generalmente se utiliza como un índice de orientación), seguida por una aceleración y una segunda desaceleración. La dimensión de valencia contribuye a la desaceleración inicial y la actividad de aceleración; un estímulo desagradable produce mayor desaceleración en comparación a un estímulo placentero que presenta el mayor pico de aceleración.

A pesar de que todavía no existe un consenso, se ha sugerido que la deceleración cardíaca permite que la información sensorial sea procesada de manera más efectiva, mientras que la aceleración promueve el rechazo o la falta de atención a estímulos desagradables o que provoquen dolor intensamente [45]). El patrón de la respuesta trifásica de la frecuencia cardíaca es el producto de la inervación al corazón de las dos divisiones del sistema nervioso autónomo (simpática y parasimpática), que tiene como función principal regular el ambiente interno por medio de nervios aferentes que llevan las señales sensoriales desde los órganos internos hacia el cerebro y de nervios motores que llevan las señales motoras desde el cerebro hacia los órganos internos. Generalmente, cuando el corazón es excitado por la rama parasimpática se produce una disminución en la tasa cardíaca (desaceleración), mientras que la rama simpática provoca un aumento en la tasa cardíaca (aceleración) [46].

4.4.2. La respuesta galvánica de piel

La respuesta fisiológica somática se refiere a la actividad electrodermal, antes conocida con el término de respuesta galvánica de la piel. Este tipo de respuesta es una herramienta de gran valor para la investigación psicofisiológica de los procesos cognitivos y emocionales inconscientes, principalmente. Se adquiere colocando un par de electrodos sobre la superficie de la palma de la mano en donde se localizan grandes núcleos de glándulas ecrinas de sudor que responden directamente al significado de un estímulo emocional.

Recientes estudios han demostrado que la conductancia de la piel (sudor) es mayor conforme aumentan los niveles de activación, a pesar de la dimensión de valencia emocional. Es decir, si se observan estímulos agradables que producen relajación o calma (ej., paisajes) o desagradables que no perturben (ej., víboras), estos provocarán un sudor en las palmas de las manos casi imperceptible. En cambio la exposición a estímulos agradables (ej. desnudos) o desagradables (ej., malformaciones) que provoquen un fuerte impacto, entonces se producirán grandes cantidades de sudor en señal de miedo o nerviosismo [36].

La respuesta somática cuenta con la gran ventaja de que las glándulas ecrinas únicamente reciben innervación colinérgica de la rama simpática del sistema nervioso autónomo, lo cual aporta una representación directa de la activación simpática. El circuito cerebral involucrado en el control de la actividad electrodermal incluye a la región inferior del lóbulo parietal, las regiones dorsolateral y ventromedial de la corteza prefrontal y el cíngulo anterior, principalmente del hemisferio derecho. En especial, la región orbitofrontal de la corteza prefrontal juega un papel importante para la actividad electrodermal generada ante estímulos que tienen un significado social [47].

4.4.3. La frecuencia respiratoria

La frecuencia respiratoria se define como las veces que se respira (ciclo de respiración: se contraen y se expanden los pulmones) por unidad de tiempo, normalmente en respiraciones por minuto. El ciclo respiratorio consiste en un proceso alternante de inspiración y expiración, durante la inspiración; los músculos esqueléticos como el diafragma y los músculos intercostales externos se contraen incrementando el volumen dentro del tórax y los pulmones. En la medida en que el volumen dentro de los espacios del aire del pulmón (Volumen intrapulmonar) se incrementa, la presión del aire dentro del mismo (Presión intrapulmonar) cae por debajo de la presión atmosférica y el aire entra al pulmón. Durante la expiración, los músculos inspiratorios se relajan haciendo que el volumen del tórax y de los pulmones se reduzca, esta última se acompaña por un incremento de la presión a intrapulmonar, forzando al gas pulmonar para regresar a la atmósfera. Cuando se requiere un aumento en la ventilación pulmonar como ocurre durante el ejercicio, la expiración se hace un evento activo, dependiente de la contracción de los músculos que empujan hacia abajo la caja torácica y que comprime los pulmones. El movimiento muscular que permite la respiración es controlado por impulsos nerviosos originados en la médula. Para ajustar la tasa respiratoria y la profundidad de acuerdo con la necesidad del cuerpo, los centros medulares reciben entradas de centros neuronales superiores (Puente, cerebelo, corteza cerebelar) y de receptores periféricos, como quimiorreceptores en los cuerpos aórticos y carótidos, los receptores de estiramiento en las uniones de los músculos y tendones y de los receptores somáticos para dolor y estímulos térmicos. La variación de la frecuencia respiratoria [48], con respecto a criterios psicofisiológicos como la ansiedad, presenta cambios en aumento en profundidad y frecuencia y aumento en respiración torácica [49].

4.4.4. Señales Electroencefalográficas (EEG)

La electroencefalografía es el procedimiento que consiste en medir las señales del cerebro con el fin de estudiar el sistema nervioso; esto se hace uniéndolos en el cuero cabelludo o en la corteza cerebral (ésta es esencial en funciones importantes del cerebro como la memoria, la atención, el conocimiento perceptivo, el pensamiento, la lengua y los sentidos), estos electrodos transmiten las señales u ondas cerebrales proporcionadas por un gran conjunto de neuronas en los individuos a los que se les practica [50]. El EEG se utiliza para probar la función del cerebro, registra las diferencias del voltaje entre las partes del cerebro, pero no mide corrientes eléctricas. Se utiliza popularmente en la experimentación pues se aplica principalmente con medidas no invasivas. Por otra parte, el paciente no necesita hablar, trasladarse, o aún demostrar ninguna

emoción para registrar los datos; el aparato puede incluso detectar señales eléctricas resultantes de respuestas secretas a los estímulos. Se debe tener en cuenta para la ubicación de electrodos, la división funcional del cerebro, en donde se pueden observar, las diferentes regiones del cerebro y la relación funcional de los mismos. Allí se puede notar que existe una región correspondiente a la iniciación de movimientos voluntarios (área premotora), otra utilizada en el control de movimientos complejos (corteza motora primaria) y otra relacionada con la corteza visual. Estas regiones, tienen la importancia de ser los puntos de origen de las señales nerviosas que se convierten en funciones específicas como el movimiento o la visualización [51]. Las formas de la señal EEG, permiten de forma muy eficaz en la supervisión y diagnóstico de ciertas anomalías como epilepsia y síncope (el desmayarse), desórdenes del sueño, el coma y la muerte cerebral. El procedimiento incluso se utiliza para evaluar casos como demencia cuando otros métodos no son prácticos como la comunicación personal. Conforme a la investigación, EEG es utilizado por los neurólogos y los psiquiatras biológicos en experimentos del laboratorio para registrar actividad cerebral y estudiar la función del cerebro en el comportamiento.

4.4.5. Señales Electromiográficas (EMG)

Las señales electromiográficas son señales eléctricas producidas al existir contracción o relajación en un músculo; estas señales han sido utilizadas durante varios años con distintos propósitos, uno de ellos es la biomedicina que mediante la determinación del tiempo de activación del músculo, la estimación de la fuerza producida por la contracción muscular y la obtención de índices de fatiga muscular es capaz de aportar información significativa a la determinación de un adecuado programa de rehabilitación de pacientes. Una señal electromiográfica se compone esencialmente de la superposición de potenciales de acción de varias unidades motoras (PAUMs). Para realizar un análisis de una señal de este tipo se requiere descomponerla en potenciales de acción unitarios [52]. Electromiografía Una de las principales técnicas para adquirir información del cuerpo es la electromiografía. La electromiografía (EMG) es el estudio de los potenciales eléctricos generados por los músculos durante el movimiento. H. Piper fue el primer investigador en estudiar EMG en 1912 Alemania, construyó un prototipo basado en un galvanómetro; en 1924 Gasser y Erlanger hicieron un estudio similar, pero ahora utilizando un osciloscopio; cuatro años después Proebster observó las señales producidas por la denervación de los músculos, abriendo así el campo de la EMG clínica. A partir de 1980 con la introducción de las computadoras se pudieron realizar grandes estudios y descomposición de las señales EMG en pocos segundos [53].

5. Marco Conceptual

Para las señales frecuencia respiratoria, Pletismógrafo, temperatura, conductividad de piel (SGR), señales de electrocardiografía (EEG), señales de electrooculografía (EOG), señales de electromiografía (EMG), se emplearon la Transformada Wavelet Discreta y las Wavelets Adaptativas, en ambas se aplicaron dos niveles de descomposición.

5.1. Transformada wavelet discreta.

La transformada wavelet discreta [54] representa una función por un conjunto enumerable de coeficientes wavelets. Si el conjunto $\{\psi_{m,n}(t)\}$ es un conjunto ortonormal, entonces se puede expresar cualquier función $x(t) \in L^2(\mathbb{R})$ como la expansión en series wavelet de la forma

$$x(t) = \sum_{m=-\infty}^{\infty} \sum_{n=-\infty}^{\infty} \langle x, \psi_{m,n} \rangle \psi_{m,n}(t). \quad (5.1)$$

donde $\langle x, \psi_{m,n} \rangle = c_{m,n}$ son los coeficientes wavelets. En la figura 5.1 se muestra una Transformada wavelet discreta con 2 niveles de descomposición.

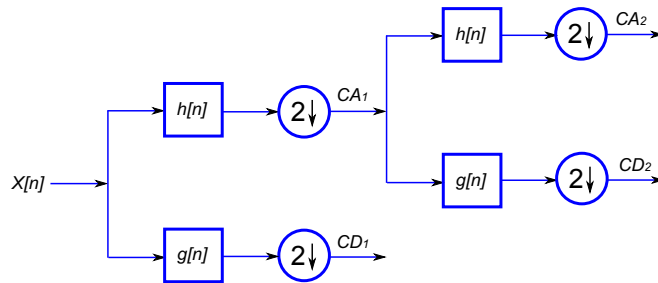


Figura 5.1.: Transformada wavelet discreta con 2 niveles de descomposición. $g[n]$ corresponde al filtro pasa alto, $h[n]$ filtro pasa bajo, CA_n son los coeficientes de aproximación y CD_n coeficientes de detalle.

En muchas aplicaciones, especialmente en el procesamiento de señales, los datos son representados por un número finito de valores, por lo que es importante considerar versiones discretas de la transformada wavelet continua. En forma general, los parámetros a y b que determinan, de manera correspondiente la escala y el desplazamiento de la función wavelet, toman valores discretos. El valor de a se selecciona igual al exponente entero (positivo o negativo) del parámetro fijo de expansión de la escala $a_0 > 1$, esto es, $a = a_0^m$, $m \in \mathbb{Z}$. El parámetro de desplazamiento debe cambiar en sincronía con la escala y, por tanto, también depende de m : $b = nb_0a_0^m$, $n \in \mathbb{Z}$, siendo $b_0 > 0$ un valor a priori fijo. De esta manera, la familia de funciones discretas

wavelet tiene la forma:

$$\psi_{m,n}(t) = \frac{1}{\sqrt{a_0^m}} \psi\left(\frac{t - nb_0 a_0^m}{a_0^m}\right) = a_0^{-m/2} \psi(a_0^{-m}t - nb_0)$$

5.2. Análisis Multi-resolución

El análisis multi-resolución se basa en aproximar una función $f(t)$ en distintos niveles de resolución, $\{f_1(t), f_2(t), f_3(t), \dots\}$, entregando una descomposición multi-escala de la forma:

$$f(t) = f_0(t) + \sum_{j \geq 0} g_j(t) \quad (5.2)$$

donde cada $g_j(t) = f_{j+1}(t) - f_j(t)$ representa el error en que se llega al aproximar $f_{j+1}(t)$, mediante $f_j(t)$, es decir, el cambio entre dos niveles sucesivos de resolución. Para dicho análisis se utiliza la función $\psi(t)$ para la señal a analizar. Esta función se encuentra ubicada en el tiempo y en frecuencia, y translaciones y escalamientos de ésta, generan una función base $\{\psi_{j,k}(t) | j, k \in \mathbb{Z}\}$, que expande $g_j(t)$ como:

$$g_j(t) = \sum_{k \in \mathbb{Z}} d_{j,k} \psi_{j,k}(t) \quad (5.3)$$

donde los $d_{j,k}$ son coeficientes escalares también llamados *coeficientes wavelet* [55]. El esquema básico del análisis multiresolución con la Wavelet Packet se ilustra en la figura 5.2.

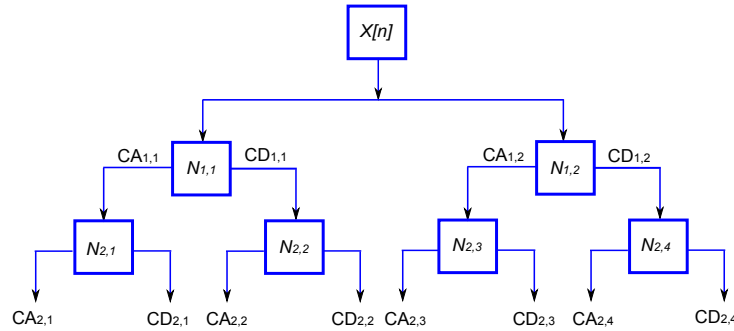


Figura 5.2.: Análisis multiresolución con la wavelet packet empleando dos niveles de descomposición. En total se obtienen 8 conjuntos de coeficientes de representación.

5.3. Esquema adaptativo de actualización dual

Las wavelets adaptativas son aquellas que modifican sus parámetros (momentos de desvanecimiento, soporte) de acuerdo con un criterio de adaptabilidad dependiente de la señal analizada. La construcción de wavelets adaptativas utilizando los esquemas de actualización adaptativos se realiza de manera similar a la construcción de wavelets fijas. Esto es, la selección adecuada de los filtros que corresponden a los operadores U y P permite que al modificar el orden del filtro se modifique el número de momentos de desvanecimiento. [56]. El esquema adaptativo se muestra en la Figura 5.3. La señal x_e es actualizada con la función U

(actualización) con el fin de obtener los coeficientes de aproximación x_L mientras que la señal x_o es actualizada con la función P (predicción) para obtener los coeficientes de detalle x_H . En este esquema de actualización la función de predicción P es adaptativa, mientras que la de actualización U es fija.




Figura 5.3.: Esquema adaptativo de actualización dual

la adaptabilidad se consigue a partir de un operador de decisión D , el cual depende del valor obtenido al aplicar el criterio de adaptabilidad s (características locales de la señal). Este operador de decisión puede tomar dos o más valores, lo que permite escoger entre dos o más filtros de actualización dual. El operador de actualización U es fijo y de orden bajo. Los filtros de predicción varían entre filtros de orden 2, 4 y 6 la etapa de actualización dual se implementa como

$$x_H[n] = x_o[n] - P_d(x_L[n]) \quad (5.4)$$

donde P_d puede ser un filtro de orden 2, 4 ó 6. Si P_d es de orden 2, se tiene

$$x_H[n] = x_o[n] - \frac{1}{4}(x_L[n] + x_L[n + 1]). \quad (5.5)$$

Si P_d es de orden 4, se tiene

$$x_H[n] = x_o[n] - \frac{1}{32}(x_L[n - 1] - 9x_L[n] - 9x_L[n + 1] + x_L[n + 2]) , \quad (5.6)$$

y así sucesivamente.

5.4. Métricas Estadísticas

Las métricas estadísticas empleadas para la caracterización, se describen a continuación

$$M_p = \max(|\mathbf{C}_p|), \text{ Maximo Valor} \quad (5.7)$$

$$E_p = \frac{1}{2} \sum_N (\mathbf{C}_p)^2, \text{ Energia} \quad (5.8)$$

$$\mu_p = \frac{1}{N} \sum_N |\mathbf{C}_p|, \text{ Media absoluta} \quad (5.9)$$

$$\sigma_p = \sqrt{\frac{1}{N-1} \sum_N (\mathbf{C}_p)^2}, \text{ Desviacion estandard} \quad (5.10)$$

5.5. Clasificador de k vecinos más cercanos (k-nn k-Nearest Neighbors)

(*k-NN*)

El proceso de aprendizaje del algoritmo K-NN (k-Nearest Neighbors) se basa en el almacenamiento de datos en la memoria. Con este método se estima la función de densidad de donde provienen un conjunto de datos y sus correspondientes etiquetas. Se estima la función de densidad $f(x/C_j)$, de las predictoras x por cada clase.

Parte de la idea de que un nuevo dato será clasificado a la clase a la cual pertenezca la mayor cantidad de vecinos más cercanos. En caso de que se produzca un empate entre dos o más clases, conviene tener una regla heurística para su ruptura como son seleccionar la clase que se encuentre con el vecino más cercano [57].

En resumen se puede decir que:

- primero se almacenan los datos de entrenamiento,
- se encuentran los k-vecinos más cercanos para un nuevo ejemplo x utilizando una distancia d en todo el conjunto de entrenamiento $\langle x_i, y_i \rangle$
- y por último dependiendo del número de vecinos que se elijan en el algoritmo, se realiza una votación para determinar la clase del nuevo dato.

las funciones para calcular la distancia son las que se encuentran en la ecuación (5.11) y (5.12).

$$\|x - x_i\| = \sqrt{\sum_j (x_j - x_{ij})^2} \quad \text{Distancia Euclidiana} \quad (5.11)$$

$$dist_{manh}(x, x_i) = \sum_j |x_j - x_{ij}| \quad \text{Distancia de Manhattan.} \quad (5.12)$$

5.6. Clasificador Bayesiano

El Clasificador Bayesiano es una metodología probabilística basada en la regla de decisión de Bayes, la cual establece que la probabilidad de la clase w_i dado el vector de características X es igual a la probabilidad *a priori* de la clase por la función de densidad de probabilidad sobre la probabilidad total de las muestras 5.13. [58].

$$P\left(\frac{w_i}{X}\right) = \frac{p\left(\frac{X}{w_i}\right) P(w_i)}{p(X)} \quad (5.13)$$

Se considera que si se tiene igual número de registros por clase, las probabilidades *a priori* de cada clase deben ser iguales y con un valor de $\frac{1}{C}$, donde C corresponde al número de clases. Para la función de densidad de probabilidad se emplea una distribución gaussiana. La varianza y la media se calculan de acuerdo a las ecuaciones 5.14 y 5.15.

$$\bar{X} = \frac{1}{n} \sum_{i=0}^{N-1} X_i \quad (5.14)$$

$$\sigma^2 = \frac{1}{n} \sum_{i=0}^{N-1} X_i^2 - \bar{X}^2 \quad (5.15)$$

Un aspecto importante al emplear distribuciones gaussianas es la selección de la matriz de covarianza, si las matrices de covarianza se asumen iguales para las clases, la regla de decisión de Bayes recibe el nombre de *discriminante lineal*, debido a que las superficies de decisión entre clases son de tipo lineal. Si se asume que las matrices de covarianza son distintas, las superficies de decisión generadas son cuadráticas y la regla de decisión recibe el nombre de *discriminante cuadrático*.

5.7. Máquinas de soporte vectorial

Una de las técnicas más recientes e interesantes en el diseño de clasificadores es la introducción de los vectores de soporte. Sea el problema de clasificación de dos clases empleando modelos lineales de la forma 5.16.

$$y(x) = w^T \phi(x) + b \quad (5.16)$$

Donde $\phi(x)$ determina una característica fija del espacio de transformación, y el parámetro b representa el *bias* de la función. El conjunto de datos de entrenamiento N comprende vectores de entrada X_n que tienen una correspondencia con los valores objetivo t_n igual a 1 ó -1. Los nuevos puntos de datos son clasificados de acuerdo al signo de la función. Asumiendo que el conjunto de características de entrenamiento es linealmente separable, de modo que exista por lo menos una elección de parámetros w y b tal que $y(x_n) > 0$ con $t_n = 1$ y $y(x_n) < 0$ para $t_n = -1$, es decir $t_n y(x_n) > 0$ para todos los datos de entrenamiento. Para los casos linealmente separables, el algoritmo busca una superficie de decisión de forma que se maximice el margen entre la superficie y los vectores de soporte. Pero en la práctica este caso no siempre sucede, en [59] se demostró que solo es posible llegar a separar tantos datos como la dimensión del espacio más una unidad y ciertos datos no pueden ser clasificados en forma lineal. La solución es llevar los datos a una dimensión mediante el uso de un *Kernel* de tal forma que en la nueva dimensión los datos sean linealmente separables. La función *kernel* es definida por $k(x, x') = \phi(x)^T \phi(x')$, la cual puede ser introducida en la ecuación 5.16 teniendo en cuenta que:

$$w = \sum_{n=1}^N a_n t_n \phi(x_n) \quad (5.17)$$

Remplazando en la ecuación 5.16 tenemos que:

$$w = \sum_{n=1}^N a_n t_n k(x, x_n) + b \quad (5.18)$$

5.8. Clasificador por Procesos Gaussianos

Al considerar un modelo definido en términos de una combinación lineal de M funciones base, dadas por los elementos del vector $\varphi(x)$ de tal forma que

$$y(x) = w^T \varphi(x) \quad (5.19)$$

Donde x es el vector de entrada y w es un vector de pesos de dimensión M . Se desea modelar la probabilidad conjunta $y(x_1), \dots, y(x_N)$ que se denota por el vector y y con elementos $y_n = y(x_n)$ para $n=1$. De la ecuación

5.19, este vector esta dado por:

$$y = \phi w \quad (5.20)$$

Donde ϕ es la matriz de diseño $\phi_{nk} = \phi_k(x_n)$, y se asume que $p(w) = N(y|0, \alpha^{-1}I)$, la función de distribución sobre w y sigue igualmente una distribución gaussiana $p(y) = N(y|0, K)$, donde K esta dada como [60]

$$K = \frac{1}{\alpha} \phi \phi^T \quad (5.21)$$

La función de probabilidad anterior $p(y)$, es un proceso particular de un proceso gaussiano. Para muchas aplicaciones se asume que la media del proceso es igual a cero y la matriz de covarianza se especifica evaluando $y(x)$ para dos valores de x , lo cual permite obtener:

$$E[y(x_n) y(x_m)] = K(x_n, x_m) \quad (5.22)$$

Donde $k(x, x)$ se conoce como la función kernel [61]. Una condición necesaria y suficiente para que la función $k(x, x)$ sea un kernel valido es que la matriz de Gram K , cuyos elementos están dados por $k(x_n, x_m)$ debe ser semidefinida positiva para todos los valores posibles de $\{x_n\}$. Cuando se emplea un proceso gaussiano para clasificación, primero se define un proceso gaussiano sobre la función $a(x)$, que luego se transforma usando una función logística sigmoidal:

$$\sigma(a) = \left(\frac{1}{1 + \exp^{-a}} \right) \quad (5.23)$$

Se obtiene entonces un proceso estocástico no gaussiano sobre las funciones $y(x)$ con $y \in \{0, 1\}$. Sea x_1, \dots, x_N el conjunto de vectores de entrenamiento con sus correspondientes etiquetas $t = (t_1, \dots, t_N)$. El objetivo es determinar la función de distribución predictiva $p(t_{N+1}|t)$. Para lograrlo, se introduce un proceso gaussiano sobre el vector a_{N+1} que tiene componentes $a(x_1), \dots, a(x_N)$. A su turno, esto define un proceso no gaussiano sobre t_{N+1} y condicionándolo sobre el conjunto de entrenamiento, se obtiene la distribución predictiva que se requiere. El proceso gaussiano para a_{N+1} toma la forma:

$$p(a_{n+1}) = N(a_{n+1}|0, C_{n+1}) \quad (5.24)$$

Donde la matriz de covarianza tiene elementos dados por:

$$C(x_n, x_m) = k(x_n, x_m) + \nu \delta_{mn} \quad (5.25)$$

Siendo $k(x_n, x_m)$ una función kernel semidefinida positiva y la constante se introduce para asegurar que la matriz sea definida positiva.

Parte III.

Materiales y Métodos

6. Materiales y Metodos

6.1. Materiales

6.1.1. Base de Datos DEAP

La base de datos DEAP esta diseñada específicamente para el análisis de los estados afectivos de las personas. Se adquieren el electroencefalograma y las señales fisiológicas periféricas de 32 participantes mientras eran estimulados mediante 40 porciones de videos musicales de 1 minuto. Los experimentos fueron llevados a cabo en 2 ambientes controlados de laboratorio con una iluminación constante. El EEG y las señales fisiológicas periféricas fueron adquiridas usando un sistema Biosemi ActiveTwo System, en un equipo de cómputo dedicado (Pentium 4, 3;2 GHz), mientras que la presentación de los segmentos de video se realiza en otro equipo dedicado (Pentium 4, 3;2 GHz). Las señales adquiridas corresponden a los 32 canales del electroencefalograma (EEG), la respuesta galvánica de la piel (GSR), la presión sanguínea, el patrón respiratorio, la temperatura de la piel, el electrooculograma (EOG) y el electromiogramas (EMG). Adicionalmente para los 22 primeros participantes se adquirió la señal de video del rostro en una posición frontal, utilizando una video grabadora Sony DCR-HC27E. Los 32 participantes estaban distribuidos equitativamente entre hombres y mujeres con edades de 19 a 32 años y cada uno realiza una valoración de cada video en términos de los niveles de activación, evaluación, gusto/disgusto, dominancia y familiaridad. Dichas valoraciones se adquieren utilizando el software Presentation de Neurobehavioral systems. Al final de cada video cada participante hace la valoración utilizando maniqués de autovaloración (SAM) que se utilizan para visualizar las diferentes escalas de evaluación. El experimento comienza con una grabación de 2 minutos de la línea basal, tiempo en el cual se le pide al paciente que se relaje para después presentar los 40 videos en 40 pruebas individuales de la siguiente forma: En la pantalla durante dos segundos aparece la información del número del video actual. Grabación de 5 segundos de línea basal. Presentación del video de un minuto. Autovaloración de los niveles de activación, evaluación, gusto y dominancia. La base de datos está disponible para descargar en archivos preprocesados en MATLAB, donde cada archivo contiene todas las señales correspondientes a cada uno de los 40 videos de cada sujeto. En la figura 6.1 se encuentra un ejemplo del sistema utilizado para la captura de las señales al igual que el criterio de evaluación de los índices de las emociones basados en maniqués [10].

6.1.2. Caja de Herramientas

Matlab R2012a : El software Matlab R2012a fue necesario para el análisis de señales fisiológicas: la frecuencia respiratoria, la frecuencia cardíaca, la conductividad de la piel, EEG, EOG, EMG. Matlab es un lenguaje de computación técnico de alto nivel para el desarrollo de algoritmos, visualización de datos, análisis de datos y computación numérica. Se utiliza Matlab para un amplio rango de aplicaciones: procesamiento de señales e imágenes digitales, telecomunicaciones, control y automatización, pruebas, medidas, modelamiento financiero y biología computacional.




Figura 6.1.: Muestra de una sesión de grabación con bd DEAP

PRTOOLS: Es la caja de herramientas de Matlab para el reconocimiento de patrones suministra más de 300 rutinas de usuario para tareas de reconocimiento estadístico de patrones tradicionales. Los PRTools pueden ser útiles para:

- Diseño de prototipos de sistemas de reconocimiento de patrones.
- Diseño y la evaluación de nuevos algoritmos.
- Integración en áreas aplicadas de análisis de datos, como la visión artificial, el diagnóstico médico, la sísmica, la teledetección, la quimiometría y la bioinformática.

Los PRTools pueden ser utilizados libremente para la investigación académica.

GPML Toolbox :La caja de herramientas GPML implementa algoritmos de inferencia aproximados para procesos gaussianos como Expectativa de propagación, la aproximación de Laplace y Variational Bayes para una amplia clase de funciones de verosimilitud, tanto para la regresión y clasificación. Viene con una poderosa álgebra de funciones de covarianza y medios que permitan la modelización flexible.

6.2. Metodología

En la figura 6.2 se ilustra la metodología empleada para el reconocimiento de niveles de ansiedad. En los siguientes puntos se detallan cada uno de los pasos metodológicos seguidos en este trabajo.

1. Se toma un minuto de cada tipo de señal, debido a que un estado de ansiedad se manifiesta en intervalos de tiempo superiores a cinco segundos [10].
2. Se aplica la transformada Wavelet discreta a las señales, empleando diferentes Wavelet madre: Daubechies (db3, db4, db5), Coiflets (coif2, coif3, coif4, coif5), Symlet (sym3, sym4, sym5), Dmeyer (dmey), y se descompone en dos niveles. De forma paralela también se procesan las señales con wavelets adaptativas basado en el esquema dual descrito en la subsección 5.3. Por cada método se obtienen cuatro conjuntos de coeficientes de representación (dos aproximación y dos de detalle).
3. Luego los coeficientes de aproximación y de detalle obtenidos en el paso 2, con análisis multi-resolución o con wavelets adaptativas, son enventanados cada 6 segundos con un traslape del 50 % y se aplican las métricas estadísticas, (media absoluta , desviación estándar, máximo valor, energía de Shannon) descritas en la subsección 5.4. Finalmente se obtienen ocho características por cada tipo




Figura 6.2.: Esquema metodológico: Las señales fisiológicas se procesan con análisis multi-resolución o wavelets adaptativas para obtener los coeficientes de representación. Luego se aplican las métricas estadísticas (ver subsección 5.4) a los coeficientes enventanados para obtener 320 características por cada realización. Finalmente se procede a la fase de validación, usando máquinas de aprendizaje supervisadas.

de señal o modo fisiológico. La base de datos cuenta con 40 modos, y por tanto para cada sujeto se extraen 320 características,.

4. Para todos los modelos de clasificación, la validación se realiza empleando el esquema Hold-Out [62] (70 % de las observaciones para entrenamiento y 30 % para validación) efectuando 10 permutaciones en la base de datos DEAP, donde se eligen aleatoriamente distintos conjuntos de entrenamiento y validación. Se mide el rendimiento de los métodos de procesamiento evaluando la precisión que entrega cada clasificador en el conjunto de validación, esto se realiza para observar la capacidad de generalización de los algoritmos.

Parte IV.

Resultados y Discusión

7. Resultados y Discusión

7.1. Resultados

7.1.1. Caracterización con ventana usando Transformada Wavelet Discreta

En la Tabla 7.1 se muestran los resultados para la caracterización dinámica empleando Análisis Multiresolución, para tres niveles de ansiedad, los que se obtuvieron con los clasificadores K-Nearest Neighbor (KNN-1 y KNN-3), clasificador Bayesiano (LDC-QDC), Máquinas de soporte vectorial (SVM) y Procesos Gaussianos (GP).

Tabla 7.1.: Resultados de clasificación de tres niveles de ansiedad para la caracterización dinámica con transformada wavelet discreta

Wavelet madre	KNN1	KNN3	LDC	QDC	SVM	GP
coif2	41.45 ± 3.70	41.46 ± 4.78	48.80 ± 2.62	44.30 ± 3.68	51.02 ± 0.90	51.70 ± 1.30
coif3	42.80 ± 4.82	41.88 ± 5.28	48.45 ± 1.67	44,97 ± 3,46	51.14 ± 0.89	51.50 ± 1.70
coif4	43,26 ± 4,16	41,64 ± 5,40	48,74 ± 1,69	44,85 ± 3,48	51,43 ± 0,49	51,70 ± 1,60
coif5	41.94 ± 3.95	41.56 ± 5.54	48.60 ± 1.58	44.53 ± 3.39	51.55 ± 0.75	51.50 ± 1.80
sym3	42.52 ± 4.06	41.24 ± 5.37	48.27 ± 2.19	44.68 ± 3.47	51.60 ± 0.99	51.40 ± 1.90
sym4	41.95 ± 3.89	41.20 ± 4.79	47.87 ± 1.50	45.23 ± 2.85	51.43 ± 0.60	51.90 ± 1.40
sym5	42.14 ± 5.45	41.45 ± 4.80	46.75 ± 3.36	43.86 ± 2.45	51.42 ± 0.61	51.40 ± 1.70
db3	42.52 ± 4.06	41.24 ± 5.77	48.27 ± 2.19	44.68 ± 3.47	51.60 ± 0.99	51.40 ± 1.90
db4	41.72 ± 3.57	41.11 ± 4.89	48.13 ± 2.05	44.39 ± 3.71	51.60 ± 0.77	50.70 ± 2.20
db5	41.87 ± 4.70	41.61 ± 4.97	48.42 ± 1.47	43.74 ± 3.65	51.14 ± 0.70	50.80 ± 1.70
dmey	42.93 ± 4.39	41,97 ± 4,35	48,92 ± 2,50	44.04 ± 3.64	52,14 ± 0,64	52,00 ± 1,30

Discusión Tabla 7.1 : Al observar los resultados de la tabla 7.1, en la que se realizó una caracterización basada en el análisis multiresolución, para tres niveles de ansiedad, los resultados muestran que: para los clasificadores K-NN1 el porcentaje de acierto es de $43,26 \pm 4,16$ con wavelet madre coif4, K-NN3 el porcentaje de acierto es de $41,97 \pm 4,35$ con wavelet madre dmey, LDC el porcentaje de acierto es de $48,92 \pm 2,50$ con wavelet madre dmey, QDC el porcentaje de acierto es de $44,97 \pm 3,46$ con wavelet madre coif3, MSV el porcentaje de acierto es de $52,14 \pm 0,64$ con wavelet madre dmey, y para PG el porcentaje de acierto es de $52,00 \pm 1,30$ con wavelet madre dmey, siendo más robusto el clasificador MSV seguido ligeramente el PG. Además cabe destacar que la Wavelet madre dmey es muy representativa en la caracterización para tres niveles de ansiedad.

Los resultados para la caracterización dinámica empleando Análisis Multiresolución, para dos niveles de ansiedad, se obtuvieron con los clasificadores K-Nearest Neighbor (KNN-1 y KNN-3), clasificador Bayesiano (LDC-QDC), Máquinas de soporte vectorial (SVM) y Procesos Gaussianos (GP), se evidencian en la Tabla

7.2

Tabla 7.2.: Resultados de clasificación de dos niveles de ansiedad para la caracterización dinámica con transformada wavelet discreta

Wavelet madre	KNN1	KNN3	LDC	QDC	SVM	GP
coif2	53.77 ± 3.55	56.12 ± 5.07	58,76 ± 2,07	58.57 ± 1.95	61.05 ± 1.28	58.80 ± 1.30
coif3	54.27 ± 3.66	55.95 ± 5.42	58.27 ± 3.18	60.50 ± 1.67	60.58 ± 1.72	58.60 ± 1.10
coif4	53.74 ± 3.70	55.66 ± 5.52	58.54 ± 3.38	60,65 ± 1,63	60.70 ± 1.26	58.60 ± 0.90
coif5	53.59 ± 3.38	55.47 ± 4.06	57.46 ± 2.32	59.39 ± 1.57	60.41 ± 2.25	58.50 ± 0.80
sym3	54.34 ± 4.22	56.32 ± 4.06	57.46 ± 2.32	59.37 ± 1.57	60.41 ± 2.25	58.70 ± 1.30
sym4	54.09 ± 3.51	56.43 ± 4.19	58.22 ± 2.32	59.85 ± 2.55	60.64 ± 1.32	58.70 ± 1.20
sym5	54.43 ± 3.28	56.16 ± 5.01	57.08 ± 2.05	58.36 ± 2.86	60.64 ± 1.15	58.70 ± 1.40
db3	54.34 ± 4.22	56.52 ± 5.77	57.46 ± 2.32	59.39 ± 1.57	60.41 ± 2.25	58.70 ± 1.30
db4	53.09 ± 3.55	55.89 ± 4.92	57.72 ± 1.98	58.68 ± 1.60	60.58 ± 1.93	59.00 ± 1.30
db5	54.49 ± 4.09	56.67 ± 4.94	58.71 ± 2.50	59.09 ± 1.57	60.76 ± 1.47	59.20 ± 1.50
dmey	55,48 ± 4,00	58,04 ± 4,78	58.13 ± 3.39	60.12 ± 2.37	61,18 ± 1,15	60,80 ± 1,50

Discusión Tabla 7.2 Al igual que en la tabla anterior, en la tabla 7.2 , se realizo una caracterización basada en el análisis multiresolución, esta vez para, dos niveles de ansiedad, siendo los resultados un poco mas representativos, esto es: para los clasificadores K-NN1 el porcentaje de acierto es de $55,48 \pm 4,00$ con wavelet madre dmey , K-NN3 el porcentaje de acierto es de $58,04 \pm 4,78$ con wavelet madre dmey, LDC el porcentaje de acierto es de $58,76 \pm 2,07$ con wavelet madre coif2, QDC el porcentaje de acierto es de $60,65 \pm 1,63$ con wavelet madre coif4, MSV el porcentaje de acierto es de $61,18 \pm 1,15$ con wavelet madre dmey, y para PG el porcentaje de acierto es de $60,80 \pm 1,50$ con wavelet madre dmey, siendo mas robusto el clasificador MSV seguido ligeramente el PG. tambien la Wavelet madre dmey es muy significativa en la caracterización para dos niveles de ansiedad.

7.1.2. Caracterización con ventana usando Wavelet Adaptativa

Para la caracterización dinámica empleando Wavelet Adaptativa, empleando los clasificadores K-Nearest Neighbor (KNN-1 y KNN-3), clasificador Bayesiano (LDC-QDC), Máquinas de soporte vectorial (SVM) y Procesos Gaussianos (GP), podemos observar los resultados en la Tabla 7.3

Tabla 7.3.: Resultados de clasificación de tres niveles de ansiedad para la caracterización dinámica con Wavelet Adaptativa

Coefic	KNN1	KNN3	LDC	QDC	SVM	GP
AWdet	43,03 ± 3,10	41,48 ± 3,10	45.48 ± 2.24	45.53 ± 2.42	52.20 ± 1.04	50.30 ± 1.10
AW	40.71 ± 3.40	40.69 ± 4.14	48,06 ± 2,89	49,60 ± 2,93	52,54 ± 0,98	52,00 ± 0,60

Discusión Tabla 7.3:

Continuando con resultados, en la tabla 7.3, donde se aplica una clasificación con el esquema de caracterización basado en Wavelets adaptativas, para tres niveles de ansiedad, los clasificadores tuvieron el siguiente comportamiento: K-NN1 el porcentaje de acierto es de $43,03 \pm 3,10$, K-NN3 el porcentaje de acierto es de $41,48 \pm 3,10$, LDC el porcentaje de acierto es de $48,06 \pm 2,89$, QDC el porcentaje de acierto es de

49,60±2,93, MSV el porcentaje de acierto es de 52,54±0,98, y para PG el porcentaje de acierto es de 52,00±0,60, donde sigue siendo mas robusto el clasificador MSV y muy próximo el PG.

Por ultimo en la Tabla 7.4 se muestran los resultados de identificación para la caraterización dinámica empleando Wavelet Adaptativa, obtenidos con los clasificadores K-Nearest Neighbor (KNN-1 y KNN-3), clasificador Bayesiano (LDC-QDC), Máquinas de soporte vectorial (SVM) y Procesos Gaussianos (GP).

Tabla 7.4.: Resultados de clasificación de dos niveles de ansiedad para la caraterización dinámica con Wavelet Adaptativa

Coefic	KNN1	KNN3	LDC	QDC	SVM	GP
AWdet	56,20 ± 2,55	55,90 ± 3,21	47,66 ± 2,22	50,00 ± 3,30	59,36 ± 1,45	59,02 ± 0,90
AW	51,91 ± 3,40	54,86 ± 4,04	51,11 ± 3,40	49,60 ± 2,93	62,16 ± 1,51	60,7 ± 1,60

Discusión Tabla 7.4: Por ultimo los resultados de la tabla 7.4, donde se aplica una clasificación con el esquema de caracterización basado en Wavelets adaptativas, pero con dos niveles de ansiedad, y el rendimiento de los clasificadores tambien mejora considerablemente: K-NN1 el porcentaje de acierto es de 56,20±2,55, K-NN3 el porcentaje de acierto es de 55,90±3,21, LDC el porcentaje de acierto es de 51,11±3,40, QDC el porcentaje de acierto es de 50,00±3,30, MSV el porcentaje de acierto es de 62,16±1,51, y para PG el porcentaje de acierto es de 60,7±1,60, donde sigue siendo mas robusto el clasificador MSV y muy próximo el PG.

7.2. Discusión General

Los resultados de las tablas 7.1 y 7.2, en los cuales se realiza la caracterización basada en análisis multi-resolución, evidencian un mayor porcentaje de acierto cuando el problema es biclase. En este caso específico sólo se consideran dos niveles de ansiedad (arousal alto y arousal bajo). Para 2 clases se obtiene el 61.18 % de acierto cuando se emplea la wavelet madre *dmey* y máquinas de soporte vectorial (SVM). Con respecto a la clasificación de tres niveles de ansiedad en los que se incluyen valores medios de arousal, se logra como máximo una identificación del 52.14 %, de nuevo para la wavelet madre *dmey* y SVM. El clasificador basado en procesos gaussianos (GP) mejora ligeramente a la SVM con 52.54 % de acierto, pero esta diferencia no es estadísticamente significativa. Aunque los PG son máquinas de aprendizaje probabilísticas, demuestran ser una herramienta robusta para clasificación y tienen una gran capacidad de generalización con pocos datos de entrenamiento. Los PG logran ajustarse a la alta variabilidad de un conjunto de entrenamiento debido al tratamiento estocástico de las funciones de verosimilitud. Esta propiedad también se conoce como robustez ante *Outliers* o posibles muestras que son mal etiquetadas.

En las tablas 7.3 y 7.4 se consignan los resultados de clasificación logrados con el esquema de caracterización basado en Wavelets adaptativas. Si se compara con los resultados del análisis multi-resolución (Tablas 7.1 y 7.2), se observa fácilmente que la wavelet adaptativa logra mejores resultados de identificación en 2 y 3 niveles de ansiedad para todas las máquinas de aprendizaje. Esto se explica porque la adaptabilidad del esquema dual permite una mejor correlación con las señales multimodales. Esta correlación se traduce en una mejor representación dinámica y espectral de la mayor parte de las señales fisiológicas. Es importante recordar que las señales fisiológicas son altamente no estacionarias, por este motivo es muy difícil representar con exactitud su comportamiento en el tiempo.

Si bien, estos resultados están acorde a lo reportado en el estado del arte, es claro que los porcentajes de acierto son susceptibles a mejorarse. El aporte de este trabajo se fundamenta en un marco de procesamiento basado en métodos de transformación tiempo-escala como el análisis multi-resolución con transformada

Wavelet discreta y la representación con wavelets adaptativa. Estos métodos tienen algunas ventajas como la facilidad en la implementación para sistemas que deben funcionar en línea y en tiempo real.

Parte V.

Conclusiones

8. Conclusiones

En este trabajo se desarrolló una metodología para el reconocimiento de niveles de ansiedad a partir del análisis multimodal en señales fisiológicas y técnicas de aprendizaje de máquina. Los resultados muestran una mejor caracterización utilizando el esquema de wavelets adaptativas en comparación con el análisis multiresolución con wavelet packet.

La adición de técnicas de aprendizaje supervisado de máquina como las SVM y los PG brindan mejores índices de clasificación, debido que mapean mejor las características extraídas a un espacio de decisión kernelizado (SVM) y probabilístico (PG). Los porcentajes de acierto obtenidos aún no son altamente precisos. Por este motivo, como trabajo futuro es recomendable implementar métodos avanzados de selección de características, tales como PCA probabilístico o reducción de dimensionalidad con métodos de sparse coding.

Bibliografía

- [1] Daniel. Goleman. *Inteligencia emocional*. 1996. 6, 8
- [2] Hamza Hamdi, Paul Richard, Aymeric Suteau, and Philippe Allain. Emotion assessment for affective computing based on physiological responses. In *FUZZ-IEEE*, pages 1–8. IEEE, 2012. 6, 7, 8
- [3] Jonghwa Kim and Elisabeth André. Emotion recognition based on physiological changes in music listening. *IEEE Trans. Pattern Anal. Mach. Intell.*, 30:2067–2083, December 2008. 6, 8
- [4] Lisetti Christine Alvarez Kaye and Finkelstein Neal. Emotion recognition from physiological signals for presence technologies. In *International Journal of Cognition, Technology and Work, Special Issue on Presence*, 6, 2003. 6, 8
- [5] M. Soleymani, J. Lichtenauer, T. Pun, and M. Pantic. A multimodal database for affect recognition and implicit tagging. *IEEE Transactions on Affective Computing*, 3(1):42–55, 2012. 6
- [6] Bong Siao Zheng, M. Murugappan, and S. Yaacob. Human emotional stress assessment through heart rate detection in a customized protocol experiment. In *Industrial Electronics and Applications (ISIEA), 2012 IEEE Symposium on*, pages 293–298, 2012. 7, 8
- [7] Byoung-Jun Park, Eun-Hye Jang, Sang-Hyeob Kim, Chul Huh, and Jin-Hun Sohn. Seven emotion recognition by means of particle swarm optimization on physiological signals: Seven emotion recognition. In *ICNSC*, pages 277–282. IEEE, 2012. 7
- [8] Ji-hua Chen Lan Li. Emotion recognition using physiological signals from multiple subjects. In *International Conference on Intelligent Information Hiding and Multimedia Signal Processing*, 2006. 8
- [9] Olivier Villon and Christine Lisetti. A user model of psycho-physiological measure of emotion. pages 319–323, 2007. 8
- [10] M. Soleymani J.-S. Lee A. Yazdani T. Ebrahimi T. Pun A. Nijholt I. Patras S. Koelstra, C. Muehl. Deap: A database for emotion analysis using physiological signals. *IEEE Transaction on Affective Computing, Special Issue on Naturalistic Affect Resources for System Building and Evaluation*. in press. 8, 9, 26, 27
- [11] J. Arroyo-palacios and D. M. Romano. Towards a standardization in the use of physiological signals for affective recognition systems. 2008. 8
- [12] Choubeila Maaoui and Alain Pruski. Emotion recognition through physiological signals for human-machine communication. 4511, 2010. 8

- [13] Gu Yuan, Tan Su Lim, Wong Kai Juan, Ho Moon-Ho Ringo, and Qu Li. A gmm based 2-stage architecture for multi-subject emotion recognition using physiological responses. pages 3:1–3:6, 2010. 8
- [14] M. Soleymani, J. Lichtenauer, T. Pun, and M. Pantic. A multimodal database for affect recognition and implicit tagging. *IEEE Transactions on Affective Computing*, 3:42–55, April 2012. Issue 1. 8
- [15] M. J. Apter. *Reversal Theory: motivation, emotion and personality*. 1989. 9, 14
- [16] Nadel L Damasio A, Lane R. A second chance of emotion. *Adv. Eng. Inform.*, pages 12–23, 2000. 12
- [17] A. Damasio. Neurobiología de la emoción y los sentimientos. 2000. 12
- [18] 2-3 Johanne Lévesque³ 4 Iglesias de Jesús, A. Mario Beauregard¹ and Pierre Bourgouin¹. Neurociencia afectiva: Perspectivas actuales en psicofisiología de la emoción. pages 29–41, 2003. 12
- [19] S.S. Tomkins. Affect as the primary motivational system. pages 101–110, 1970. 13
- [20] R. D. Lane, E. M. Reiman, M. M. Bradley, P. J. Lang, G. L. Ahern, R. J. Davidson, and G. E. Schwartz. Neuroanatomical correlates of pleasant and unpleasant emotion. *Neuropsychologia*, 35(11):1437–1444, November 1997. 13
- [21] R.J. Davidson. Cerebral asymmetry and emotion: conceptual and methodological conundrums. pages 115–138, 1993. 13
- [22] M. Bradley y B.N. Cuthbert Lang. Technical manual and affective ratings. technical report a-4. pages 115–138, 1999. 13
- [23] R. Plutchik. Las emociones. 1987. 13
- [24] J. Reeve. Motivación y emoción. 1994. 13
- [25] A.I Rosenzweig, M.R. y Leiman. Psicología fisiológica. 1992. 13
- [26] J.E. LeDoux. The emotional brain: The mysterious underpinnings of emotional life. 1996. 13
- [27] Mauri D. Palomba H. Flor-N. Birbaumer G. Sartori y F. di Paola Angrilli, A. Startle reflex and emotion modulation impairment after a right amygdale lesion. pages 115–138, 1996. 13
- [28] E.T. Rolls. The brain and emotion. 1999. 13
- [29] P. y W.V. Friesen Ekman. Unmasking the face. 1975. 13
- [30] Bradley M.M. y P.J. Lang. Affective norms for english words (anew), technical manual and affective ratings. 1999. 13
- [31] A. Iglesias de Jesús y F. Ostrosky Castillo-Parra, G. Valencia, activación y tiempos de reacción ante estímulos visuales con contenido emocional. 2002. 13
- [32] Kim Y.K. y S. Watanuki (2003). Characteristics of electroencephalographic responses induced by a pleasant and an unpleasant odor. 2003. 13
- [33] S. y Y.K. Kim Watanuki. Physiological responses induced by pleasant stimuli. 2005. 13

- [34] Jones A.L. y N.A. Fox. Electroencephalogram asymmetry during emotionally evocative films and its relation with positive and negative affectivity. 1992. 13
- [35] F. A. Barrios R. Favila-Humara M. A. Guevara Y. del Río-Portilla y M. Corsi-Cabrera Flores-Gutiérrez EO., J.L. Díaz. Metabolic and electric brain patterns during pleasant and unpleasant emotions induced by music masterpieces. 2007. 13
- [36] Bradley M.M.y P.J. Lang. Measuring emotion: behavior, feeling, and physiology. 2000. 13, 17
- [37] F. Palmero. *Aproximación biológica al estudio de la emoción*. 14
- [38] David M Buss Randy J. Larsen. *Psicología de la personalidad, los dominios del conocimiento sobre la naturaleza humana*. 2008. 14
- [39] Apter M. J. 14
- [40] Moore Jackson M. M. & Birch G. E. Mason, S. G. A general framework for brain-computer interface design. pages 1–18, 2005. 15
- [41] Dua U. Moore, M. M. A galvanic skin response interface for people with severe motor disabilities. 2004. 15
- [42] & Birch G. E. Mason, S. G. A general framework for brain-computer interface design. pages 70–85, 2003. 15
- [43] Q. Mason, H. D. Trotter, C. T. H. Davies, K. Foley, A. Gray, G. P. Lepage, M. Nobes, and J. Shigemitsu. Accurate determinations of α_s from realistic lattice qcd. *Phys. Rev. Lett.*, 95(5):052002, Jul 2005. 15
- [44] D. Goleman. *Inteligencia emocional*. Barcelona: Editorial Kairos. Barcelona., 1996. 16
- [45] Bradley M.M.P.J. Lang y B.N. Cuthbert. Emotion, novelty, and the startle reflex: habituation in humans. 1993. 16
- [46] W. J. Ray y K.S. Quigley Stern, R. M. Psychophysiological recording. 1993. 16
- [47] D. Tranel. Electrodermal activity in cognitive neuroscience: neuroanatomical and neuropsychological correlates. 2000. 17
- [48] J. Martinez. Psicofisiología. 1995. 17
- [49] Fernandez E. C. Palmero. Emociones y adaptacion. 1998. 17
- [50] RANGARAJ M. RANGAYYAN. Biomedical signal analisis. 2002. 17
- [51] Uwe. WINDHORST. Modern techniques in neuroscience research. 1999. 18
- [52] GUYTON Arthur. Anatomia y fisiologia del sistema nervioso: Neurociencia basica. 1997. 18
- [53] Philip. Merletti, Roberto; Parker. Electromyography - physiology, engineering, and noninvasive applications. 2004. 18
- [54] S. Mallat. A wavelet tour of signal processing. 1999. 19

- [55] Greer M. H. Udpa L. Keinert F. Polikar, R. Multiresolution wavelet analysis of erps for the detection of alzheimer's disease. 20
- [56] A. Orozco. Clasificación de patrones provenientes de señales de actividad biológica no estacionaria. aplicación a la cirugía de la enfermedad de parkinson. 2002. 20
- [57] Allen L. Barker, Worthy N. Martin (advisor, Donald E. Brown, Advisor Minor Representative, James P. Cohoon (chair, John L. Pfaltz, James C. French, and Richard W. Miksad (dean. Selection of distance metrics and feature subsets for k-nearest neighbor classifiers, 1997. 22
- [58] Jason D. M. Rennie, Lawrence Shih, Jaime Teevan, and David R. Karger. Tackling the poor assumptions of naive bayes text classifiers. In *In Proceedings of the Twentieth International Conference on Machine Learning*, pages 616–623, 2003. 22
- [59] V. Vapnik. *The Nature of Statistical Learning Theory*. Springer, 2000. 23
- [60] C. Bishop. *Pattern Recognition and Machine Learning*. 2006. 24
- [61] A. Smola. B. Scholkopf. *Learning with Kernels: Support Vector Machines, Regularization, Optimization and Beyond*,. 24
- [62] *The holdout method, The school of computer science*. 1997. 28