

Análisis espectral de parámetros fisiológicos para la detección de emociones

Spectral analysis of physiological parameters for consumers' emotion detection

Camilo E. Valderrama C.

cevalderrama@icesi.edu.co

Gonzalo Ulloa Ph.D.

gulloa@icesi.edu.co

Grupo de Investigación en Informática y Telecomunicaciones - i2T

Facultad de Ingeniería

Universidad Icesi, Cali, Colombia

Fecha de recepción: Febrero 24 de 2012

Fecha de aceptación: Marzo 20 de 2012

Palabras clave

Electro Encefalograma (EEG), Emociones, Procesamiento de Señales, Transformada Discreta Wavelet (DWT), Interfaces cerebro-computador (BCI), Redes Neuronales.

Key words

Electro encephalogram (EEG), Emotions, Signal Processing, Discrete Wavelet Transform (DWT), Brain-Computer Interfaces (BCI), Neural Networks, Support Vector Machine (SVM).

Resumen

En el trabajo se aborda una revisión bibliográfica en el campo de la detección de emociones. Se muestra el gran impacto de las aplicaciones de interfaz cerebro-computador (BCI) y su funcionalidad. Se explica cómo trabajar con las señales neuronales y cómo extraer información de ellas utilizando la Transformada Discreta Wavelet (DWT). También se mencionan los métodos que se usan para la clasificación y caracterización. El objetivo del escrito es revisar el estado del arte para establecer las bases de un proyecto que busca analizar los parámetros del cerebro cuando un televidente observa un comercial publicitario.

Abstract

This paper show a literature review in the field of emotions detection. Show the strength of applications of Brain Computer Interfaces (BCI) and what the functionality of it is. Explain how work with neurosignal and how to extract information using Discrete Wavelet Transform to recognize some characteristics that are present in the signal. Also explain the methods which are used for classification the signals. The purpose of the review is established a basis for the development of a project which want define the behavior of brain signal's when a person sees a commercial advertisement.

.....

I. Introducción

Actualmente existe gran interés en la detección de estados mentales humanos a través del análisis de parámetros fisiológicos del cerebro. Así es como continuamente se busca desarrollar aplicaciones informáticas automatizadas que reciban información directa a través de la conexión cerebro-computador, contando así con entradas objetivas y reduciendo las anomalías que se presentan en los métodos tradicionales por el alto grado de libertad inherente a las respuestas suministradas por los usuarios. Es decir que las señales EEG se convierten en fuentes electrofisiológicas de control para las aplicaciones (Bashashati, Fatourehchi, Ward, & Birch, 2007).

Estas aplicaciones se utilizan en diferentes campos, como son entretenimiento (juegos basados en actividad cerebral), seguridad (monitoreo de pacientes), salud y *neuromarketing* (análisis de la decisión de compra de los consumidores). Lo referente a mercadeo ha logrado gran impacto debido al interés de las empresas por definir mejores productos; se analizan las señales eléctricas producto de la actividad cerebral para detectar el gusto o disgusto inconsciente de los consumidores (Cookson, 2011). Todo esto es posible debido al avance en los métodos de obtención de estas señales, como también al procesamiento utilizado para la extracción de características que permitan establecer patrones para inferir estados mentales.

Algunos ejemplos de los avances tecnológicos en estos campos son la detección precoz de Alzheimer a través del procesamiento de señales neuronales (Jacques, G., Frymiare, J.L.; Kounios, J.; Clark, C.; & Polikar, R., 2005). También se ha utilizado para la clasificación de órdenes de movimiento (derecha, izquierda), mediante el análisis de componentes de frecuencia de las señales neuronales (Pei & Zheng, 2008), como a la vez algunas tareas más complejas como multiplicación, composición, contar, rotar objetos, entre otras, para lo cual se utilizaron 6 señales de entrada que se procesaron con la transformada rápida de Fourier (Nakayama, 2007). En áreas comerciales, se ha utilizado el EEG para explorar reacciones a diferentes mensajes publicitarios de televisión (Young, 2002).

En el campo práctico también se han demostrado resultados: durante la conferencia de “*Neuromarketing* y Subconsciente” en Sopot, Polonia realizado entre el 17 y 18 de enero de 2008, se mostró como el EEG ha contribuido a mejorar la publicidad de Nivea. Este método ha permitido elegir las mejores escenas que influyen potencialmente en la percepción de la marca y aumentar la efectividad de la publicidad (Kwiatkowska, 2008).

Aprovechando el avance en esta área, se ha planteado un proyecto que busca detectar a través del análisis espectral de señales de electroencefalografía (EEG) gusto o disgusto hacia ciertos productos comerciales. En este documento se pretende mostrar la revisión bibliográfica realizada sobre trabajos relacionados, con el fin de contextualizar el estado del arte, como a la vez, establecer bases que conduzcan al desarrollo de lo que se desea realizar.

En la segunda sesión se explican las generalidades de la información cerebral. En la tercera se abordan las emociones. En la cuarta se detallan los métodos de preprocesamiento de señales neuronales, para en la quinta explicar la transformada discreta Wavelet (DWT), la cual es utilizada para el procesamiento. La sexta describe el método de eliminación de ruido y en la séptima, la extracción de características. Posteriormente, en la octava sesión se explica cómo se realiza la clasificación de señales. Finalmente, se concluye sobre la revisión bibliográfica.

II. Generalidades

Al realizar ciertas tareas o recibir estímulos externos se altera la actividad cerebral. Existen dos métodos con los cuales esta se puede observar: *el registro unicelular y las imágenes cerebrales* (AlMejrad, 2010). Las limitaciones del primero radican en que es un método invasivo, requiere cirugía cerebral en los pacientes, necesita medicación, y además se cuenta con tiempo restrictivo para la experimentación. En cambio, el segundo método cuenta con la ventaja de que no es invasivo, no requiere cirugía y posee alta velocidad y buena precisión. Algunas técnicas de este método son: Tomografía por Emisión Positrónica (PET), Resonancia Magnética Funcional (fMRI), Electroencefalografía (EEG), Electroencefalografía Magnética (MEG), Resonancia Magnética (MRI) y Simulación de Estimulación Magnética Transcraneana (TMS).

De todas las técnicas de imágenes cerebrales que existen, la Electroencefalografía (EEG) es la más recurrida debido a su facilidad de manejo y los menores costos comparados con las demás. Éste es un procedimiento que consiste en medir las señales del cerebro con el fin de estudiar el sistema nervioso (Rangayyan, 2002). Se mide la actividad eléctrica de un grupo de células neuronales de la corteza cerebral o del cuero cabelludo. Contiene información física, fisiológica y patológica, por lo que se analiza y se procesa para diagnóstico médico de varias enfermedades cerebrales, y también es utilizado en investigaciones científicas de procesos cognitivos (Zhang, Yin, & Wang, 2011). Cuenta con las siguientes características:

- » Las señales son débiles y con fuerte ruido en el fondo. El promedio de la señal de EEG es de $50\mu\text{V}$, el valor máximo es de $100\mu\text{V}$.
- » Es una señal aleatoria y no periódica en estado estacionario, es decir, sus propiedades estadísticas varían con el tiempo.

Aunque la técnica fMRI posea un mayor poder para entender lo que sucede en las capas bajas del cerebro e identifique los procesos que suceden en la mente (Bookheimer, 2004), este método perturba fuertemente el ambiente en el cual se somete al sujeto de estudio por el uso del equipo de resonancia. Es un método costoso y difícil para que sea usado masivamente. Por su bajo costo, ser mínimamente invasivo y no perturbar el ambiente, se utiliza más el EEG. De esta forma, en los últimos años, aprovechando la información suministrada por el EEG, se han tratado de identificar emociones humanas a través del análisis de las señales producto de la actividad cerebral. Esto ha permitido que la detección de emociones se esté convirtiendo en algo importante para la interacción humano-

computador, ya que se busca que las aplicaciones obtengan los parámetros fisiológicos, procesen la señal e inmediatamente ejecuten cierto comando, evitando así depender de una entrada física suministrada por los periféricos tradicionales. Se establece de esta forma un sistema de comunicación que permite al usuario transmitir su intención al mundo exterior a través del pensamiento sin depender de los canales de salidas normales usadas en las interfaces hombre- máquina que se basan en el uso de los nervios y de músculos Wolpaw, Birbaumer, McFarland, Pfurtscheller, & Vaughan, 2002). Este procedimiento se puede visualizar en la Figura 1 (García, Tsoneva, & Nijholt, 2009).

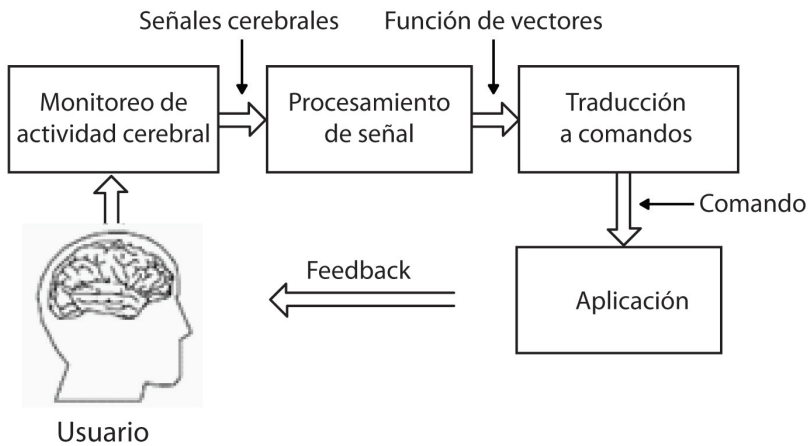


Figura 1. Modelo funcional de detección de emociones a través del EEG (García et al, 2009).

III. Emociones

Las emociones se han estado analizando con el EEG por más de dos décadas. Se captura la actividad neuronal en escala de milisegundos de toda la zona cortical y se procede a la identificación a través de cambios fisiológicos, pues de antemano se han establecido diferentes características fisiológicas para cada una de las emociones humanas (Cacioppo & Tassinary, 1990). De esta forma, científicos han llegado a construir base de datos de análisis de emociones a través del uso de señales fisiológicas (Koelstra, Muhl, Soleymani, Lee, Yazdani, Ebrahimi, & Patras, 2011).

Las emociones son una simple expresión que consiste en sentimientos y pensamientos, como también son procesos internos inconscientes (AlMejrad, 2010). Sin embargo, la detección de emociones es una actividad con muchos retos porque hasta ahora no se cuentan con métodos maduros para su clasificación. Estudios anteriores han clasificado las emociones basándose en la conductancia cutánea, el ritmo cardiaco y la temperatura (Picard, 2000). Sin embargo, actualmente se ha comprobado que después de percibir un evento externo, se generan experiencias inmediatas e individuales que generan cambios neurofisiológicos. Las ondas cerebrales generadas son óptimas y efectivas, debido a que

son excitadas en el sistema límbico, y están profundamente relacionadas con procesos cognitivos (Picard, Vyzas, & Healey, 2001).

Actualmente, para clasificar una emoción existen dos técnicas. La primera consiste en un conjunto discreto de emociones básicas, de las cuales se pueden generar otras secundarias (Arnold, 1960). Así, las emociones humanas están básicamente clasificadas en tres categorías (AlMejrad, 2010): motivación (sed, hambre, dolor, humor), básicas (feliz, triste, miedo, disgusto, ira, sorpresa) y sociales (encanto, pena, orgullo, culpa). Finalmente, de estas categorías se puede establecer un conjunto de 6 emociones básicas las cuales pueden ser generadas fácilmente (felicidad, tristeza, disgusto, miedo, alegría e ira).

La otra técnica consiste en medir y contextualizar las emociones de acuerdo a diferentes dimensiones, cada una de las cuales representa un trato afectivo. Un ejemplo de esta aproximación es el modelo excitación-emoción, la primera dimensión es la excitación (valencia), que explica el deseo, y la segunda explica la actividad fisiológica relacionada con el estado afectivo (Lang & Bradley, 1994). La validez de esto radica en la relación entre la característica fisiológica y la excitación debido a la activación del sistema nervioso automático cuando la emoción es generada. La Figura 2 corresponde a la representación de las dos dimensiones.

Existen varios métodos para generar las emociones. Principalmente se evocan usando elementos visuales (imágenes, fotos), audiovisuales (videos/cortometrajes), recordando experiencias del pasado o audios (sonidos/canciones). A través de varios estudios se ha comprobado que los más eficaces son los materiales audiovisuales. Además, de acuerdo a estudios anteriores, se ha demostrado que el material audiovisual es un método más efectivo en la generación de emociones que el visual (Murugappan, Rizon, Nagarajan, & Yaacob, 2009).

(AlMejrad, 2010) El procedimiento con el cual se expone al usuario con el material audiovisual consiste en neutralizar primero el ambiente mediante escenas naturales y

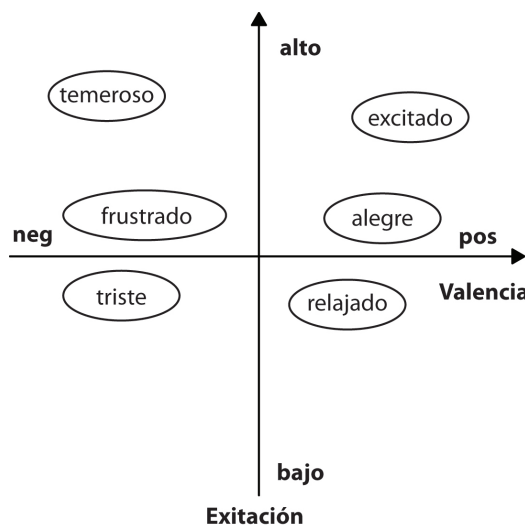


Figura 2. Modelo de Clasificación de emociones (Lang & Bradley, 1994).

sonidos calmantes, y una vez transcurra un tiempo, se empiezan a mostrar los videos correspondientes a cada una de las emociones, colocando una pantalla oscura en el intermedio de cada video. La información cerebral es almacenada y para fines de comparación, se le solicita al sujeto que diligencie un cuestionario donde indique la sensación generada por cada video. Estos experimentos se realizan con un EEG de 64 electrodos y utilizando el sistema internacional 10-20 o 10-10, con una tasa de muestreo de 256 muestras por segundo y digitalizadas a 16 bits. Generalmente se aplica a un grupo aproximadamente de 20 personas entre los 20 y 40 años. La Figura 3 muestra la secuencia de tiempos para el proceso de visualización de los videos.

Se puede observar en la gráfica que existe un video para cada sensación y que hay un espacio entre cada emoción (pantalla negra) para neutralizar al usuario.

El sistema 10-20 al que se refiere, es un sistema utilizado para la ubicación de los electrodos en el cuero cabelludo para la obtención de las señales neuronales (Windhorst, 1999). El 10 y el 20 se refieren a los porcentajes de medidas en la distancia entre los electrodos. La Figura 4 ilustra el sistema.

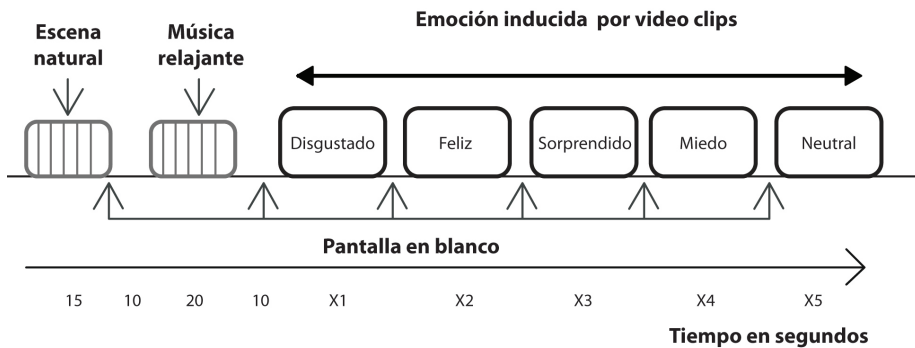


Figura 3. Proceso de adquisición de emociones (Murugappan, Nagarajan, & Yaacob, 2010).

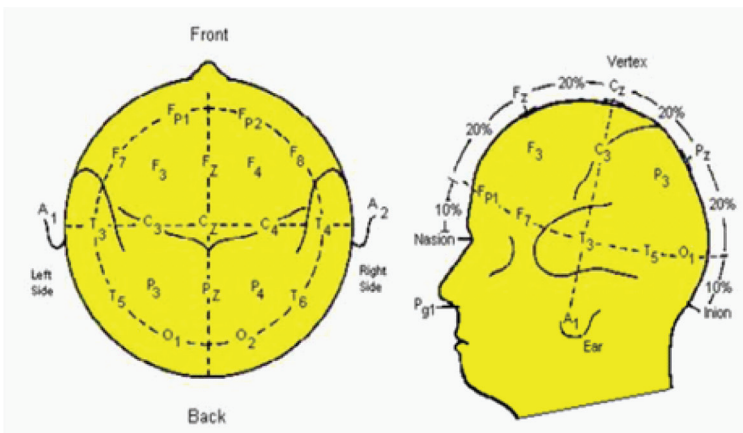


Figura 4. Sistema 10-20 (Windhorst, 1999).

Cada punto se representa por una letra para identificar un lóbulo y un número u otra letra para identificar la localización del hemisferio. Así, las letras F, T, C, P y O, representan los lóbulos frontal, temporal, central, parietal y occipital respectivamente. Los números pares (2, 4, 6 y 8) se refieren al hemisferio derecho, mientras que los impares (1, 3, 5 y 7) se refieren al izquierdo. La Z identifica los electrodos de la línea media.

IV. Preprocesando la señal

La actividad eléctrica generada en el cerebro es obtenida por el EEG, sin embargo, existen diferentes componentes de la señal que no son originados neurológicamente. Estas señales, que no son generadas en el cerebro, pero que están presentes en el EEG, son llamadas Artefactos y son generados principalmente por parpadeo, efectos musculares y vasculares y por brillo cinético. La detección de la emoción se altera por la presencia de estos ruidos, por lo que es necesario eliminarlos, y así trabajar solamente con la porción de información útil de la señal. De esta forma, la eliminación de ruido inhibe la parte inútil de la señal y la restaurar utilizando solo la parte útil (Guerrero Martínez, 2010).

Para eliminar estos ruidos de la señales se recurre a técnicas de procesamiento digital. La técnica más común en el filtrado del ruido es la transformada de Fourier, la cual por definición es *el prisma matemático que descompone una función en las frecuencias que le forman* (Cortés, Cano, & Chaves, 2007a). En el procedimiento se expande la señal por triangulación de base de senos y cosenos, expresando una señal con sus diferentes frecuencias a través de la superposición lineal de las funciones armónicas. Aunque Fourier permite representar una señal en sus frecuencias, no tiene una resolución en tiempo, por lo que no funciona para análisis local; se pueden conocer los componentes principales de la frecuencia pero no saber en qué momento ocurrió. Sin embargo, esto se puede solucionar recurriendo a la Transformada Corta de Fourier (FFT), la cual calcula la transformada por segmentos, teniendo una representación tiempo-frecuencia de la señal que permite conocer sus armónicas en la ubicación del tiempo.

Sin embargo, el uso de la transformada de Fourier es útil solo para señales periódicas en estado estacionario, y no sirve para procesamiento de señales neuronales, pues la mayoría de las señales biológicas son no estacionarias (Agretti & Monzón, 2001), lo cual quiere decir que su espectro varía con el tiempo. Para lograr una localización temporal de los componentes espectrales se utilizan otras transformadas, que sí permiten una representación tiempo-frecuencia de la señal.

La transformada que permite procesar señales no estacionarias obtenidas en el EEG, es la Transformada Discreta Wavelet (DWT), la cual provee la representación tiempo frecuencia de la señal, y además, analiza la señal con distintas resoluciones para las diferentes frecuencias. Cuando las frecuencias son altas, se tiene buena resolución en el tiempo, pero mala en la frecuencia. Contrariamente, se tiene buena resolución de frecuencia y mala resolución de tiempo en las bajas frecuencias.

V. Transformada Discreta Wavelet (DWT)

Wavelet es una onda limitada durante un tiempo, que posee un valor promedio de cero. Es buena para describir anomalías, pulsos y otros eventos que empiezan y terminan dentro de la señal. Permite realizar análisis localizados en tiempo de una gran señal, brindando la posibilidad de encontrar discontinuidades o picos de corta duración que de otra manera sería complicado detectar y tratar (Cortés, Cano, & Cháves, 2007b). El análisis de Fourier por sí solo no detectaría estos eventos y se debe recurrir a la transformada corta que a través de la escogencia de una ventana de ancho adecuado permitiría el estudio de manera aceptable. No obstante, la transformada Wavelet combina las dimensiones tiempo y frecuencia permitiendo la extracción de los detalles y de las aproximaciones de la señal; resultado que no puede ser logrado con la transformada rápida de Fourier ni por la transformada Corta de Fourier (Mallat, 1989).

La transformada Wavelet es una técnica de estimación espectral en donde cualquier función general puede ser expresada como una serie infinita de ondeletas. La idea de esto es representar la función como una combinación lineal de un conjunto particular de funciones, obtenidas mediante la translación y escalamiento de una función básica llamada Wavelet Madre. De esta forma, a través de adecuados valores de escalamiento y desplazamiento en el tiempo, se establece un método efectivo para el procesamiento de señales bioeléctricas no estacionarias (Pardue, Landry, & Clark, 1995).

El principio de la transformada se basa en una translación telescópica de la Wavelet básica (Zhang et al., 2011), denotada por:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right),$$

Donde a y b son llamados el parámetro de escala y de posición respectivamente. La transformada Wavelet de cualquier función $f(t)$ se obtiene mediante el producto interno de la función $f(t)$ con la función wavelet.

$$W_f(a,b) = \{f(t), \Psi_{a,b}(t)\}$$

La transformada Wavelet es un análisis tiempo-frecuencia y refleja el estado de la función $f(t)$ en la escala (frecuencia) y en la posición (tiempo).

Existe un largo número de familias Wavelet conocidas y funciones que proveen un rico espacio en el que se puede buscar una onda que represente eficientemente la señal de interés. Entre las familias se encuentran: Bi-ortogonal, Coiflet, Harr, Symmlet, Daubechies. La elección de la Wavelet depende de la aplicación en la que se esté trabajando, no obstante, se busca seleccionar la que más coincida con la señal que se desea procesar (Anderson & Sijercic, 1997).

El análisis de multiresolución de la transformada Discreta Wavelet permite descomponer la señal en varios niveles. Dentro de cada nivel se utiliza un par de filtros que cortan

el dominio de la frecuencia a la mitad. Para el proceso de multiresolución se comienza dividiendo la señal original en coeficientes de aproximación (CA) y coeficientes de detalle (CD). Después, los coeficientes de aproximación son nuevamente divididos en nuevos coeficientes de aproximación y detalle. Se sigue realizando lo anterior hasta obtener el conjunto de coeficientes de aproximación y detalle para el nivel de resolución requerido (Chethan & Cox, 2002). Las Figuras 5 y 6 muestran el funcionamiento de la DWT para el primer nivel (Fugal, 2009).

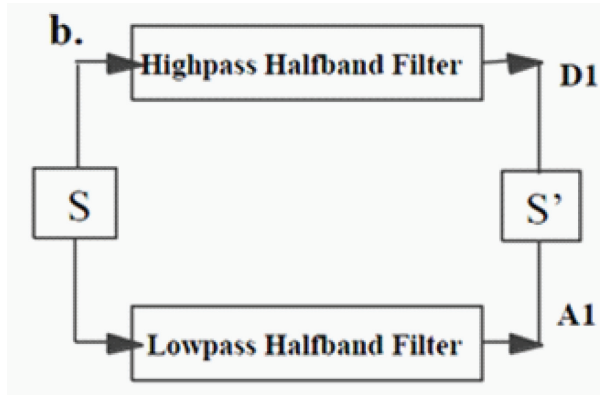


Figura 5. Estructura básica de la DWT (Fugal, 2009).

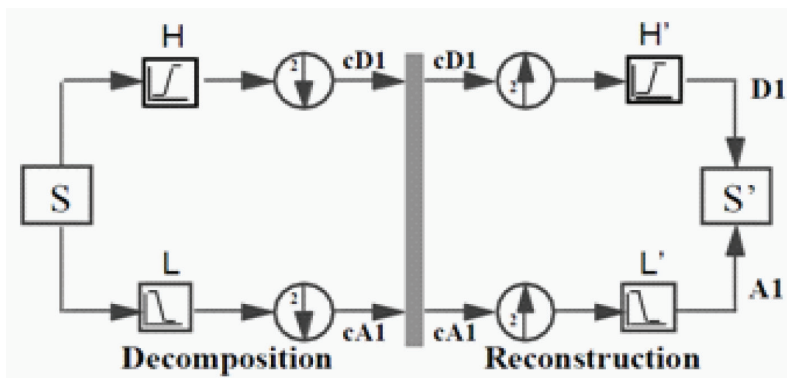


Figura 6. Estructura de la DWT para el primer nivel (Fugal, 2009).

Como se observa en la última gráfica, en la DWT además de los filtros paso-bajos y paso-altos, son necesarias también otras dos operaciones, *downsampling* y *upsampling*. La primera consiste en eliminar el valor de la muestra intercaladamente, es decir, si se tiene $S = [10 \ 10 \ 20 \ 30]$ y le aplicamos el *downsampling* se obtendría $S = [10 \ 30]$. La segunda operación consiste en agregar 0 entre cada elemento del conjunto, es decir, si se toma la salida del ejemplo anterior y se le aplica *upsampling* se tendría $S = [0 \ 10 \ 0 \ 30 \ 0]$.

Para entender cómo funciona la descomposición de una señal se realizará una demostración

para un caso particular. Primero, se debe seleccionar el tipo de Wavelet con la que se trabaja, debido a que se está trabajando con señales EEG se utiliza la Wavelet Daubechies 4 (db4) aprovechando la correlación que existe entre ellas. Para una descomposición de dos niveles se tendría una estructura como la que muestra la Figura 7.




Figura 7. Estructura de la DWT para dos niveles (Fugal, 2009).

Los cuatro filtros que se tienen para Db4 (Pywavelets, 2008), son para descomposición, $H = [-0.2304 \ 0.7148 \ -0.6309 \ -0.0280 \ 0.1870 \ 0.0308 \ -0.0329 \ -0.0106]$ y $L = [-0.0106 \ 0.0329 \ 0.0308 \ -0.1870 \ -0.0280 \ 0.6309 \ 0.7148 \ 0.2304]$, y para reconstitución se tiene, $H' = [-0.0106 \ -0.0329 \ 0.0308 \ 0.1870 \ -0.0280 \ -0.6309 \ 0.7148 \ -0.2304]$ y $L' = [0.2304 \ 0.7148 \ 0.6309 \ -0.0280 \ -0.1870 \ 0.0308 \ 0.0329 \ -0.0106]$. Si se tiene una señal de entrada $S = [80 \ 80 \ 80 \ 80 \ 0 \ 0 \ 0 \ 0]$, se procesaría de la siguiente manera (se utiliza comando de MatLab para facilidad en los cálculos):

```
[C, L] = wavedec (S, 2,'db4'); %Se utilizan dos niveles de resolución y la Wavelet madre db4.
%primer nivel
D (1,:) = wrcoef ('d',C,L,'db4',1)
D (1,:) = 1.1434 -8.5091 1.5517 27.1752 -28.2034 -0.5236 9.6599 -2.2941
A (1,:) = wrcoef ('a',C,L,'db4',1)
A (1,:) = 78.8566 88.5091 78.4483 52.8248 28.2034 0.5236 -9.6599 2.2941
%segundo nivel
D (2,:) = wrcoef ('d',C,L,'db4',2)
D (2,:) = -5.2128 9.8348 8.8335 -5.5172 -10.6808 -10.9003 -4.8555 11.6203
A (2,:) = wrcoef ('a',C,L,'db4',2)
A (2,:) = 84.0694 78.6743 69.6148 58.3420 38.8841 11.4238 -4.8044 -9.3262
```

Finalmente se comprueba que las señales obtenidas al sumarse den como resultado la original.

```
D (1,:)+D (2,:)+A (2,:);
ans = 80.0000 80.0000 80.0000 80.0000 0.0000 0.0000 0.0000 0.0000
```

Efectivamente, la suma de las señales detalles y la última de aproximación dan como resultado la señal original. Se puede observar esto visualmente en la Figura 6, donde S es la suma de D1, D2 y A2.

En el ejemplo anterior se pudo observar cómo una señal se puede representar a través de las sumas de otras. Estos componentes pertenecen cada uno a un rango de frecuencia, tal como se ilustra en la Figura 8 (Fugal, 2009).

Cada vez que se realiza una descomposición se divide la frecuencia a la mitad, por lo que se puede conocer cuáles son los componentes de la señal que pertenecen a cada banda de frecuencias.




Figura 8. División en la banda de frecuencias (Fugal, 2009).

VI. Eliminar ruido de la señal

Para eliminar las imperfecciones de la señal debido a los Artefactos o ruidos, se puede utilizar la transformada Wavelet, que se basa en la eliminación del ruido de las altas frecuencias y las partes relevantes de las bajas frecuencias y luego reconstruir para formar la señal filtrada (Yu, 2009). El procedimiento para llevarlo a cabo consiste en: realizar la DWT, obtener los coeficientes y eliminar aquellos que sean considerados ruido. La Figura 9 ilustra el proceso (García, Velandia, & Barón, 2006).

El procedimiento anteriormente descrito se denomina umbralización. En este, una vez calculados los coeficientes de la señal para diferentes niveles de descomposición, se seleccionan solamente los coeficientes que superen un umbral determinado para considerarlos en la reconstrucción de la señal, mientras que los coeficientes por debajo del umbral se eliminan (Burrus, Ramesh, & Guo, 1999).



Figura 9. Proceso de umbralización (García et al, 2006).

La umbralización se puede llevar a cabo por varios métodos, los más utilizados son la tipo dura y la tipo suave (Ballesteros, 2004). En la suave, el umbral se aplica de acuerdo a la función:

$$f(x) = \begin{cases} x - th & x > th \\ 0 & |x| \leq th \\ x + th & x < -th \end{cases}$$

Mientras que en la tipo dura, se aplica con la siguiente:

$$f(x) = \begin{cases} x & |x| > th \\ 0 & |x| \leq th \end{cases}$$

Así, se tiene que en la tipo Dura, se eliminan todos los coeficientes que estén delimitados por el umbral y su inverso, mientras que en la tipo Suave, además de eliminar estos coeficientes, se les aplica un escalonamiento a aquellos que estén por encima del umbral o por debajo de su inverso, como lo ilustra la Figura 10.

Antes de aplicar el umbralización se debe estimar el valor de ruido presente en la señal, además debe ser escalado. Se pueden utilizar los siguientes comandos de MatLab para estas tareas. Se tiene para la estimación:

- » *Rigsuere*: Utiliza la estimación de riesgo de Stein de la señal en un segmento dado. Una vez estimado el riesgo de un umbral en particular, se minimiza el riesgo y se da la selección del valor del umbral.
- » *Sqtwlog*: El nivel de ruido se calcula con la expresión umbral igual a $\sqrt{2 \times \log n}$, donde n corresponder al número de muestras del segmento de la señal.

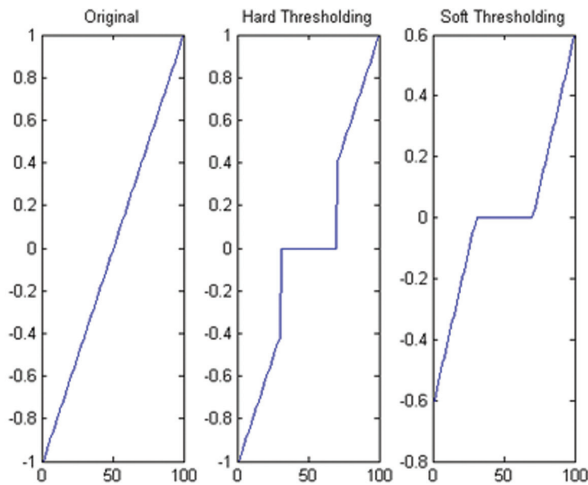


Figura 10. Métodos de umbralización (García et al., 2006).

- » *Heursure*: Compara el valor del umbral estimado con *rigsure* y el *sqtzolog* y selecciona el menor.
- » *Minimaxi*: Realiza la estimación a partir del umbral igual a $0.3936 + 0.1829 \times \left(\frac{\log n}{\log 2}\right)$

Una vez se ha calculado el umbral, se debe escalar su valor mediante alguno de los siguientes comandos:

- » *One*: Al utilizar esta opción se escala el umbral por uno.
- » *SLn*: Calcula la ponderación con la media de coeficientes de detalle del primer nivel de descomposición, dividido entre 0.6745, es decir $\sigma = \text{media}(|d1|)/0.6745$.
- » *Mln*: Calcula el escalamiento nivel por nivel, es decir, aplica el mismo concepto de *sln* para todos los niveles de descomposición $\sigma_i = \text{media}(|d_i|)/0.6745$.

A partir de estudios previos (García et al., 2006), se puede determinar de acuerdo a la umbralización que:

- » La umbralización de tipo *Suave* es mejor en la eliminación de ruido que la tipo *Dura*.
- » El tipo de estimación del umbral *Rigsuere* predomina sobre los otros métodos.
- » El mejor tipo de escalamiento para el umbral estimado es el *SLn*, superando a *One* y *Mln*.

Finalmente, se puede resumir el proceso de eliminación del ruido de la siguiente manera. Se parte de una señal expresada como $X = S + N$, donde S representa la señal útil y N el ruido. Se espera recuperar la señal que ha sido contaminada con ruido. Así, se aplica la transformada wavelet a la señal; se obtienen los coeficientes Wavelet; se realiza la umbralización sobre los coeficientes; y se aplica la transformada Wavelet inversa (Mukul & Matsuno, 2009). La reconstrucción de la señal se realiza con todos los coeficientes de los niveles de descomposición de salida de los filtros paso alto (detalles) y los coeficientes del último nivel de salida del filtro paso bajos (aproximación). La señal obtenida al final no es igual a X , no obstante, es una señal que representa mejor la señal original antes de haber sido afectada por el ruido, contando así con una información más confiable.

VII. Extracción de características.

Para la extracción de características se vuelve a recurrir a la DWT para separar según sus frecuencias, pues normalmente las características básicas presentes en las señales del EEG se detectan al separarla en diversas bandas de frecuencia (Learned & Willsky, 1995). Las ondas cerebrales están conformadas por diferentes rangos de frecuencias, como se vislumbra en la Figura 11 (Murugappan, Nagarajan, & Yaacob, 2010).

Se observa que existen 5 bandas:

- » Ondas Delta, frecuencias entre 0,5 y 3,5 Hz.
- » Ondas Theta, se encuentran entre 3 a 7 Hz. Generalmente muy presentes en recién nacidos y en adultos con discapacitados.
- » Ondas Alpha, se encuentran en un rango de frecuencia de 8 a 13 Hz. Generalmente están presentes cuando el cuerpo está en reposo, con los ojos cerrados y sin recibir estímulos externos.
- » Ondas Beta, están entre 14 a 30 Hz, se generan cuando el sujeto es expuesto a un estímulo externo. No tienen un periodo tan extenso como las alpha.

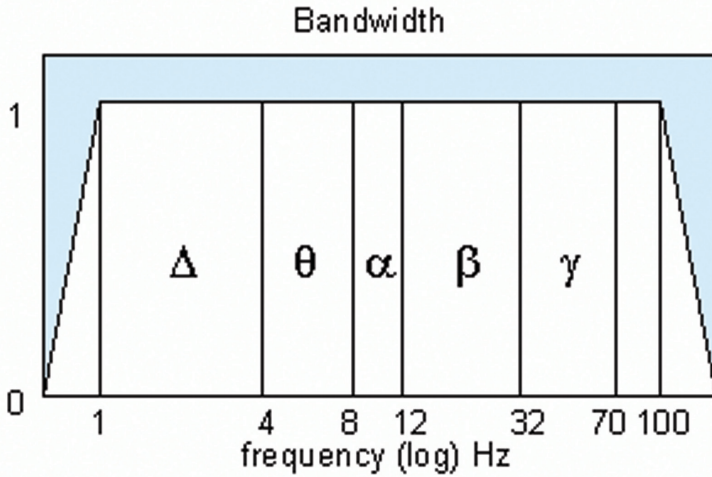


Figura 11. Bandas de frecuencias del EEG (Murugappan et al, 2010).

» Gamma, poseen una frecuencia mayor a los 30 Hz.

Las bandas de mayor atención para la detección de emociones son las alpha, beta y gamma, por lo que se realiza la descomposición fijándose en ellas. Para esto se realizan los niveles de descomposición de *wavelets* necesarios para cubrir éstas bandas. Por ejemplo, si la tasa de muestreo de la señal es de 256 Hz, se podría realizar la división de frecuencias que muestra la Tabla 1.

La extracción de los coeficientes Wavelet provee una representación que muestra la distribución de la energía de la señal EEG en tiempos y frecuencias. Se utilizan los parámetros básicos como energía, potencia, potencia media, desviación estándar, media, varianza, para reducir la dimensión de los coeficientes Wavelets, y contar con vectores de caracterización más pequeños y manejables(Kandaswamy, Kumar, Ramanathan, Jayaraman, & Malmurugan, 2004). En estudio realizado para la detección de epilepsia, se

Tabla 1. División de frecuencias a una tasa de muestreo de la señal de 256 Hz (Murugappan et al., 2010).

Rango de frecuencias (Hz)	Nivel de descomposición	Bandas de frecuencia	Ancho de banda de frecuencias (Hz)
0 – 4	A5	Delta	4
4 – 8	D5	Theta	4
8 – 14	D4	Alpha	6
14 – 32	D3	Betha	18
32 – 64	D2	Gama	32
64 – 128	D1	Noises	64

identificaron algunos estadísticos que tuvieron una alta efectividad en el diagnóstico de la enfermedad (Jahankhani, Kodogiannis, & Revett, 2006), estos fueron:

- » Máximo coeficiente Wavelet en cada sub-banda.
- » Mínimo coeficiente Wavelet en cada sub-banda.
- » Media de los coeficientes Wavelet en cada sub-banda.
- » Desviación estándar de los coeficientes Wavelet en cada sub-banda.

En la Tabla 2 se puede ver como aplicaron estos estadísticos sobre los coeficientes Wavelet de 4 niveles sobre dos poblaciones de estudio (A y E).

Tabla 2. Estadísticos aplicados a la población (Jahankhani et al., 2006).

Datos	Coefficientes Wavelet	Sub - banda D4	Sub - banda D4	Sub - banda D4	Sub - banda D4	Aproximación
Set A	Máximo	28.1094	101.757	131.0846	124.377	114.138
	Mínimo	-28.4010	-60.813	-149.072	-158.797	-109.521
	Media	-0.0022	0.0058	-0.0035	0.0388	3.7950
	Desviación estándar	5.1818	13.6442	23.3685	24.7933	35.1465
Set E	Máximo	123.3921	278.924	429.6621	375.0564	582.3167
	Mínimo	-90.7055	-238.51	-417.120	-468.064	-361.2154
	Media	0.0131	-0.0281	-0.0359	-0.0071	-5-5526
	Desviación estándar	11.8488	35.9941	73.7659	78.1432	180.4493

VIII. Identificación de la emoción.

Una vez se tienen las características principales de la señal EEG, se recurren a varios métodos para la clasificación (Procházka, Kukul & Vysata, 2008); se pueden recurrir a varios métodos estadísticos como a técnicas de inteligencia artificial, entre las que se encuentran Maquinas de Soporte Vectorial (SVM), Redes Neuronales (NN), Análisis de Discriminante Lineales (LDA), Algoritmos Genéticos (GA) entre otras. Existen estudios que demuestran la utilidad de contar con métodos de inteligencia artificial para facilitar la clasificación acertada de señales EEG (Huaping, 2011).

Normalmente, SVM tiene una buena fundamentación sólida en teorías de aprendizaje estadístico y garantiza una óptima función de decisión para el conjunto de entrenamiento de los datos, convirtiéndolo en un mejor clasificador de señales EEG que LDA y las redes neurológicas convencionales (Walpow et al, 2002).

Se desea construir algún modelo que automatice la clasificación de la señal EEG. A partir de un conjunto de características de la señales en el EEG, se espera que determine lo emoción del sujeto. A continuación se describen algunas de las técnicas de Inteligencia Artificial.

Red Neural

Redes Neuronales Artificiales (NN) son sistemas de cómputos o modelos matemáticos hechos por un número de elementos simples y altamente conectados, llamados nodos o neuronas artificiales que abstractamente emulan la estructura y las operaciones biológicas del sistema nervioso. El aprendizaje en éstas NN es realizado a través de reglas basadas en mecanismos biológicos. La reacción ante diferentes entradas depende de la topología que contenga la red, encontrándose redes de conexión hacia adelante, redes de conexión lateral y mapas autoorganizativos (Vélez, & Saldarriaga, 2010), de esta forma, se cuentan con varios tipos de redes de acuerdo a la forma en que aprenden. Estudios anteriores han clasificado varias señales EEG a través de clasificadores llamados Red Neuronal Perceptrón Multicapas (MLPNN) (Dreiseitl & Ohno-Machado, 2002).

MLPNN es una arquitectura que contiene dos o más capas. Para clasificadores de sistemas no lineales, se utiliza una capa de entrada, una de salida y unas capas intermedias entre ambas. Dependiendo de la complejidad del programa, una o varias capas son seleccionadas, sin embargo, generalmente se utiliza una red de tres capas para afrontar el problema. En la Figura 12 se vislumbra este tipo de red.

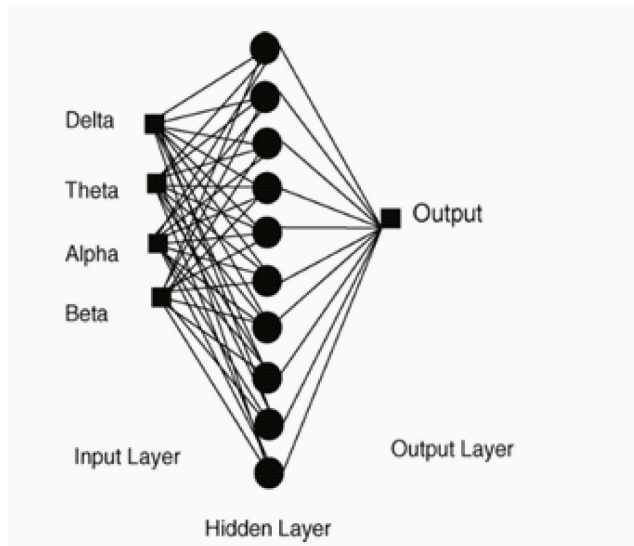


Figura 12. Arquitectura de Red Neuronal Perceptrón Multicapas (Subasia & Ercelebi, 2005).

No se sabe a ciencia exacta cómo definir el número de capas intermedias que debería tener una red neuronal. Si contiene pocas capas escondidas, podría tener inconvenientes para clasificar patrones complejos, pero si tiene demasiadas la sobreparametrización generaría ruido. El de ensayo y error es el método más óptimo para determinar cuántas capas ocultas debe contener la red (Basher & Hajmeer, 2000).

Cada capa que conforma la red cuenta con un número determinado de neuronas. Su funcionamiento es el siguiente: cada neurona recibe varias conexiones de neuronas

anteriores o de los elementos de entrada, realiza una ponderación de las entradas con el peso asociado a cada una, y una vez obtenido un valor, este es introducido en una función de activación. Dependiendo del valor obtenido, la neurona genera una salida la cual es transmitida a la siguiente capa (Nilsson, 1998). La Figura 13 muestra el esquema del funcionamiento de una red neuronal.

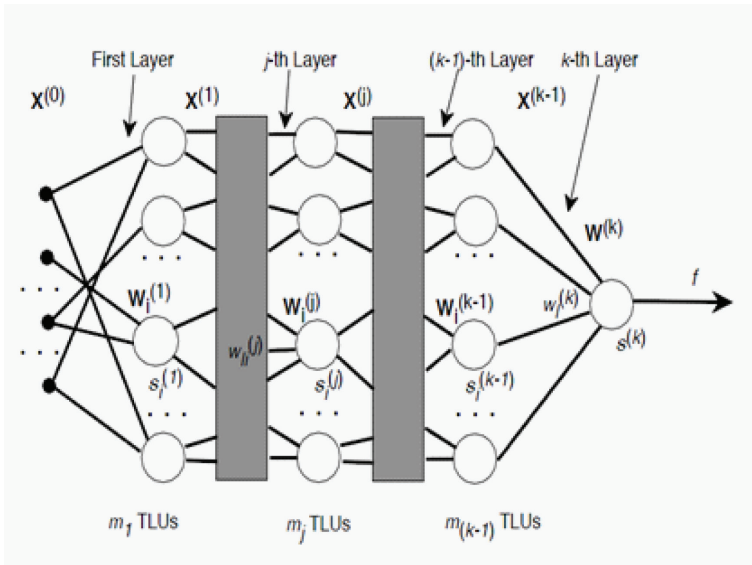


Figura 13. Funcionamiento de la red neuronal Perceptrón Multicapas (Nilsson, 1998)

La red aprende a clasificar mediante el algoritmo de aprendizaje, un proceso mediante el cual se ajustan los pesos de las conexiones para obtener las salidas que correspondan a las deseadas. El ajuste se hace mediante un proceso de *backpropagation*, que consiste en un algoritmo basado en la búsqueda del error de superficie usando gradiente descendiente minimizando (Fausett, 1994). El procedimiento trabaja con aprendizaje supervisado, es decir, se entrena con un conjunto de señales de las cuales se sabe su clasificación *a priori*; se ajustan los pesos de tal forma que coincidan lo más posible con las salidas deseadas.

Una vez se ha entrenado la red con un conjunto de datos con respuesta conocidas, se debe probar la red con un nuevo conjunto de datos, calculando el porcentaje de acierto y a la vez estableciendo cuan tan efectiva es para clasificar. En caso de no obtener una red con un nivel adecuado de aceptación, se deben hacer cambios en los parámetros (número de capas, iteraciones, error cuadrado deseado, etc.) y probar nuevamente. Se espera obtener una red adecuada que garantice una buena clasificación de las emociones.

Maquinas de Vectores de Soporte (SVM)

Las máquinas de vectores de soporte son modelos que se han popularizado en los últimos años en campos de la clasificación, el análisis de regresión y la detección primaria (Bishop, 2006). SVM se basa en un algoritmo que establece un hiperplano que separa de forma

óptima a los puntos de una clase de la de otra que han sido previamente proyectados en un espacio de dimensionalidad superior. Es capaz de llevar a cabo la construcción del modelo con un subconjunto de los datos de entrenamiento, convirtiéndola en una técnica de mayor eficiencia computacional. El concepto de la SVM se basa en maximizar el discriminante marginal, formulando una solución que se resuelva usando optimización cuadrática por métodos de Lagrange (Sherwood & Derakhshani, 2009).

SVM fue creado bajo las teorías de aprendizaje estadístico y ha sido utilizado en extensivas investigaciones de ingeniería y machine learning. La salida de un clasificador SVM tiene la siguiente expresión (Kousarrizi, Asadi Ghanbari, Teshnehlab, Aliyari, & Gharaviri, 2009):

$$y = \text{sgn} \left(\sum_{i=1}^N \alpha_i y_i k(x_i, x) + b \right)$$

Donde, (x_i, y_i) son muestras de entrenamiento, con vectores de entrada x_i y clases $y_i \in [-1, 1]$; $\alpha_i \geq 0$, son los multiplicadores de Lagrange obtenidos de resolver el problema de optimización cuadrática; b es la *bias* o *intercepto*; y $k(x_i, x_j)$ es la función de Kernel, donde la más usada es la Gaussiana RBF denominada por:

$$k(x_i, x_j) = \exp \left(\frac{-\|x_i - x_j\|^2}{2\sigma^2} \right)$$

Se puede vislumbrar la separación de clases que realiza SVM al terminar su funcionamiento en la Figura 14 (Chandaka, Chatterjee, & Munshi, 2008). En investigaciones previas se ha

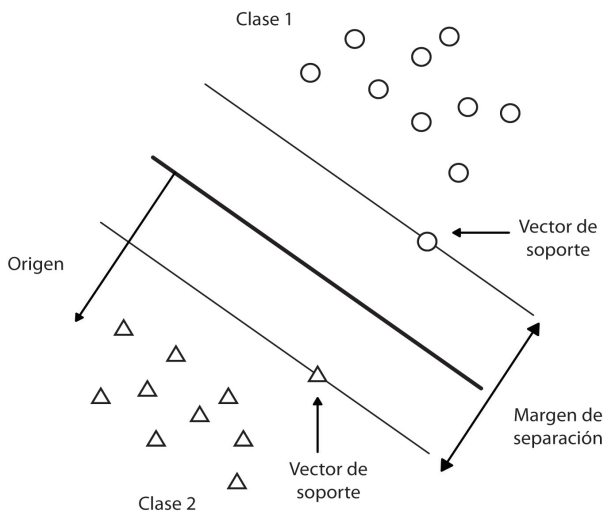


Figura 14. Funcionamiento de la red neuronal Perceptrón Multicapas (Nilsson, 1988)

comparado SVM con otras técnicas de clasificación, y se ha concluido que la SVM tiene una mejor precisión al clasificar. Además SVM es un clasificador binario, lo cual lo hace un candidato muy fuerte para problemas de clasificación con 2 clases (Kotsiantis, 2007).

Conclusiones

Actualmente, se tiene un gran interés en poder detectar comportamientos del consumidor y decisiones de compra a través de señales EEG (Sørensen, 2008). Se cree que se puede atacar este problema a través de los mismos principios utilizados aquí para la detección de emociones y clasificación de señales EEG. Actualmente se ha demostrado que se es capaz de entender lo que sucede en la mente a través de técnicas de bioinformática (Reading the brain...,2011). De esta forma, se sabe que se debe muestrear un grupo de aproximadamente 20 personas entre edades de 20 a 40 años. Se les debe ubicar en un ambiente tranquilo y ponerlos en contacto con material audiovisual. Los registros cerebrales se deben almacenar, con la transformada Wavelet se debe eliminar el ruido como también realizar su separación en bandas de frecuencias. Una vez se tengan los coeficientes de cada banda, utilizar parámetros estadísticos que permitan establecer un patrón en la señal cuando existe gusto o disgusto hacia un estímulo audiovisual. El encargado de automatizar la clasificación es la red neuronal, que analiza los datos de entrada y construye un modelo matemático que realiza la distinción del gusto. De esta forma, quedan establecidos algunos principios por los cuales se puede comenzar a abordar nuestro proyecto. \square

Referencias bibliográficas

- Agretti, H., & Monzón, J. (2001). *Análisis espectral de electrocardiograma*, Universidad Nacional de Nordeste, Argentina. Recuperado de <http://www.unne.edu.ar/Web/cyt/cyt/2002/08-Exactas/E-034.pdf>
- AlMejrad, A.S. (2010). Human emotions detection using brain wave signals: A challenging. *European Journal of Scientific Research*, 44(4), 640-659.
- Anderson, C. W., & Sijiercic, Z. (1997). Classification of EEG signals from Four Subjects during five mental tasks. En *IEEE Proceedings of the conference on engineering application in neural networks, EANN'96*. pp. 407-414. <http://sce.uhcl.edu/boetticher/CSCI5931%20Computer%20Human%20Interaction/Classification%20of%20EEG%20signals%20from%20four%20subjects%20during%20five%20mental%20tasks.pdf>
- Arnold, M. B. (1960). *Emotion and personality*. New York, NY: Columbia University Press.
- Ballesteros, D. (2004). Aplicación de la transformada Wavelet Discreta en el filtrado de señales bioeléctricas. *Umbral Científico*, 5, 92-98.
- Bashashati, A., Fatourech, M., Ward, R., & Birch, G. (2007). A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals. *Journal of Neural Engineering*,

- 4(2), R32-R57.
- Basher, I. A., & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1), 3-31.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. New York, NY: Springer Science + Business Media
- Bookheimer, S. (2004). *What brain imaging can tell us about developmental disorders* [Documento en línea]. Department of Psychiatry and Biobehavioral Sciences, UCLA, School of Medicine. Recuperado de http://www.thehelpgroup.org/pdf/guide/Book_brainimaging.pdf
- Burrus, S., Ramesh, A., & Guo, H. (1999). *Introduction to Wavelets and Wavelets transforms*. New York, NY: Prentice Hall.
- Cacioppo, C. J., & Tassinari, L. G. (1990). Inferring physiological significance from physiological signals. *American Psychologist*, 45(1), 16-28
- Chandaka, S., Chatterjee, A., & Munshi, S. (2008). Cross-correlation aided support vector machine classifier for classification of EEG signals. *Expert Systems with Applications*, 36(2), 1329-1336
- Chethan, P., & Cox, M. (2002). Frequency characteristics of wavelets. *IEEE Transactions on Power Delivery*, 17(3), 800-804.
- Cookson, C. (2011, Dic.21). A head start with brainwaves [Publicación en línea]. *Financial Times*. Recuperado de <http://www.ft.com/cms/s/0/557ff0b0-228e-11e1-8404-00144feabdc0.html#axzz1qqQJqphq>.
- Cortés, J., Cano, H., & Chaves, J. (2007a). Del análisis de Fourier al las Wavelets: Análisis de Fourier. *Scientia et Technica*, XIII(34), 151-156.
- Cortés, J., Cano, H., & Chaves, J. (2007b). Del análisis de Fourier al análisis Wavelets: transformada continua Wavelet (TCW). *Scientia et Technica*, XIII(30), 133-138.
- Dreiseitl, S., & Ohno-Machado, L. (2002). Logistic regression and artificial neural network classification models: a methodology review. *Journal of Biomedical Informatics*, 35, 5-6, 352-359.
- Fausett, L. (1994). *Fundamentals of neural networks architectures, algorithms and applications*. New York, NY: Prentice Hall.
- Fugal, L. (2009). *Conceptual wavelets in digital signal procesing*. San Diego, CA: Space & Signals Technologies.
- García, G., Tsoneva, T., & Nijholt, A. (2009). *Emotional brain-computer interfaces* [Documento en línea]. Recuperado de http://hmi.ewi.utwente.nl/abci2009_files/EmotionalBrain-ComputerInterfaces.pdf
- García, G., Velandía, R., & Barón, E. (2006). Algoritmo de la reducción de ruido en señales de electroencefalografía utilizando la DWT. *Umbral Científico*, 8, 34-40. Recuperado de <http://redalyc.uaemex.mx/pdf/304/30400805.pdf>
- Guerrero, J. (2010.). *Procesado Digital de Bioseñales* [Documento en línea]. Universidad de Valencia. Recuperado de http://ocw.uv.es/ingenieria-y-arquitectura/1-5/ib_material/IB_T4_OCW.pdf
- Huaping, J. (2011). Neural network in the application of EEG signal classification method, En *7th International Conference on Computarional Intelligence and Security. Hainan, China*, pp. 1325-1327. Los Alamitos, CA: IEEE Computer Society. doi: 10.1109/CIS.2011.294
- Jacques, G., Frymiare, J.L., Kounios, J., Clark, C. & Polikar, R. (2005). Multiresolution wavelet analysis and ensemble of classifiers for early diagnosis of alzheimer disease. En *IEEE International Conference on Acoustics, Speech, and Signal Processing, 2005. Proceedings. (ICASSP '05). Vol.5*. pp. 389-392. Piscataway, NJ: IEEE.
- Jahankhani, P., Kodogiannis, V., & Revett, K. (2006). EEG signal classification

- using wavelet feature extraction and neural networks. En *IEEE John Vincent Atanasoff 2006 International symposium on modern computing 2006 JVA'06*, pp 120-124. Los Alamitos, CA: IEEE Computer Society. doi: 10.1109/JVA.2006.17 .
- Kandaswamy, A., Kumar, C. S., Ramanathan, R., Jayaraman, S., & Malmurugan, N. (2004). Neural classification of lung sound using wavelet coefficients. *Computers on Biology and Medicine*, 34(6):523-537.
- Koelstra, S., Muhl, C., Soleymani, M., Lee, J.-S., Yazdani, A., Ebrahimi, T., Patras, I. (2011). DEAP: A database for emotion analysis using physiological signals [In press]. *IEEE Transactions on Affective Computing. Special Issue on Naturalistic Affect Resources for System Building and Evaluation*, 1-15. Recuperado de http://www.eecs.qmul.ac.uk/mmv/datasets/deap/doc/tac_special_issue_2011.pdf
- Kotsiantis, S. B. (2007). Supervised machine learning: a review of classification techniques. *Informatica*, 31, 249-268.
- Kousarrizi, M. R.N, Asadi Ghanbari, A., Teshnehlab, M., Aliyari, M., & Gharaviri, A.A, Teshnehlab, M., Aliyari, M., & Gharaviri, A. (2009). Feature extraction and classification of EEG signals using Wavelet transform, SVM and artificial neural networks for brain computer interfaces. En *International Joint Conference on Bioinformatics, Systems Biology and Intelligent Computing, IJCBS '09, Sahngai, China*, pp. 352-355. Los Alamitos, CA: IEEE Computer Society.
- Kwiatkowska, J. (2008). Management of Consumer's Attention – What can the advertiser did to survive the media revolution [Documento en línea]. Czestochowa University of Technology. Recuperado de <http://www.oeconomica.uab.ro/upload/lucrari/1020082/61.pdf>
- Lang, P. J., & Bradley, M. M. (1994). Measuring emotion: The self-assessment manikin and the semantic differential. *Journal of Behavioral Therapy and Experimental Psychiatry*, 25(1), 49-59. <http://www.cnbc.pt/jpmatmos/29.%20Bradley.pdf>
- Learned, R. E., & Willsky, A. S. (1995). A Wavelet Packet Approach to transient signal classification. *Applied Computer Harmonic Analysis*, 2, 265-278. http://ssg.mit.edu/~willsky/publ_pdfs/129_pub_ACH.pdf
- Mallat, S. G. (1989). A theory for multi-resolution signal decomposition: The Wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7), 674-693.
- Mukul, M. K., & Matsuno, F. (2009). EEG de-noising based on wavelet transforms and extraction of sub-band components related to movement imagination. En *ICAAS-SICE, 2009, Fukuoka, Japón*, pp. 1605-1610. Tokyo, Japón: The Society of Instrument and Control Engineers (SICE)
- Murugappan, M., Nagarajan, R., & Yaacob, S. (2010). Classification of human emotion from EEG using discrete Wavelet transform. *Journal of Biomedical Science and Engineering*, 3(4), 390-396. doi: 10.4236/jbise.2010.34054
- Murugappan, M., Rizon, M., Nagarajan, R., & Yaacob, S. (2009). An Investigation on visual and audiovisual stimulus based emotion recognition using EEG. *International Journal of Medical Engineering and Informatics*, 1(3) pp. 342-356. doi: 10.1504/IJMEI.2009.022645
- Nakayama, K. (2007). A brain computer interface based on FFT and multilayer neural network - feature extraction and generalization. En *Proceedings of 2007 International symposium on intelligent signal processing and communication systems. Xiamen, China*, pp. 826-829. IEEE circuit and Science Society. doi: 10.1109/

- ISPACS.2007.4446015
- Nilsson, N. (1998). *Introduction to machine learning*. Stanford, CA: Standford University
- Pardue, J.H., Landry, J.P., & Clark, T.D., Jr. (1995). A soft systems approach to input distribution estimation for a non-stationary demand process. En *WSC '95 Proceedings of the 27th conference on Winter simulation*, pp. 982-987. Washington, DC: IEEE Computer Society. doi: 10.1145/224401.224761
- Pei, X. & Zheng, C. (2008). Classification of left and right hand motor imagery tasks based on EEG frequency component selection. En *The 2nd International conference on bioinformatics and biomedical engineering, ICBBE 2008*, pp. 1888-1891. Piscataway, NJ: IEEE. doi: 10.1109/ICBBE.2008.801
- Picard, R. W. (2000). *Affective Computing*. Cambridge, MA: MIT Press.
- Picard, R. W., Vyzas, E., & Healey, J. (2001). Towards Machine Emotional Intelligence: Analysis of Affective Physiological State. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(10), 1175-1191.
- Procházka, A., Kukul, J., & Vysata, O. (2008). Wavelet transform use for feature extraction and EEG signal segments classification. En *3rd International Symposium on Communications, Control and Signal Processing, 2008. ISCCSP 2008, St. Juliens, Malta*, pp. 719-722. Piscataway, NJ: IEEE.
- Pywavelets (2008-2012). Wavelet daubechies 4 (db4). En Wavelet browser [Sitio Web]. Recuperado de <http://wavelets.pybytes.com/wavelet/db4/> http://media.economist.com/sites/default/files/imagecache/full-width/images/print-edition/20111029_STD001_0.jpg
- Rangayyan, R. M. (2002). *Biomedical signal analysis: A case-study approach*. New York, NY: IEEE Press.
- Reading the brain. Mind-goggling (2011, Oct. 29). *The Economist*. Recuperado de <http://www.economist.com/node/21534748>
- Sherwood, J., & Derakhshani, R. (2009). On classifiability of wavelet features for EEG-based brain-computer interfaces. En *International joint conference on neural networks, 2009. IJCNN 2009*, pp. 2895-2902. Piscataway, NJ: IEEE. doi: 10.1109/IJCNN.2009.5178939
- Sørensen, J. (2008). Measuring emotions in a consumer decision making context – Approaching or avoiding [working paper] Aalborg University, Dinamarca. Recuperado de <http://www.business.aau.dk/wp/08-20.pdf>
- Subasia, A., & Ercelebi, E. (2005). Classification of EEG signals using neural network and logistic regression. *Computer Methods and Programs in Biomedicine*, 78(2), 87-89.
- Vélez, P., & Saldarriaga, H. (2010). *Clasificación básica de neuroseñales [Tesis de maestría]*. Universidad Tecnológica de Pereira.
- Windhorst, U. (1999). *Modern Techniques in Neuroscience Research*. Berlín, Alemania: Springer Verlag.
- Wolpaw, J., Birbaumer, N., McFarland, D., Pfurtscheller, G., & Vaughan, T. (2002). Brain computer interfaces for communication and control. *Clinical Neurophysiology*, 113(6), 767-791.
- Young, C. (2002). Brain waves, picture sorts, and branding moments. *Journal of Advertising Research*, 42(4), 42-53
- Yu, L. (2009). EEG De-Noiseing Based on Wavelet Transformation. En *3rd International Conference on Bioinformatics and Biomedical Engineering, Beijing, China*, pp. 1-4. New York, NY: Curran. doi: 10.1109/ICBBE.2009.5162680
- Zhang, X., Yin, L., & Wang, W. (2011). Wavelet Time-frequency Analysis of Electroencephalogram (EEG) Processing. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 1(5), 1-5.

Currículum vitae

Camilo Ernesto Valderrama Cuadros

Ingeniero de Sistemas y estudiante de la Maestría en Informática y Telecomunicaciones de la Universidad Icesi de Cali (Colombia). Actualmente hace parte del programa de Jóvenes Investigadores de Colciencias y, como tal, trabaja en el proyecto *Análisis espectral de parámetros fisiológicos para la detección de emociones en el consumidor*. Sus áreas de interés son el aprendizaje de máquina, la optimización y la minería de datos.

Gonzalo Ulloa, Ph.D.

Doctor en Ciencias Técnicas de la Escuela Politécnica Federal de Lausanne, EPFL (Suiza). Ingeniero Electricista de la Universidad del Valle. Se desempeña como Decano de la Facultad de Ingeniería de la Universidad Icesi. Fue Profesor del posgrado en redes de comunicaciones de la Universidad del Valle y profesor asistente en la cátedra de informática industrial de la Escuela Politécnica Federal de Lausanne (Suiza). Ha sido consultor en tecnologías de información y telecomunicaciones y ha participado en proyectos con el Estado y la empresa privada en temas de informática, telecomunicaciones, tecnologías de información y negocios electrónicos.