

UAH

**PROCESADO DE SEÑAL DE EEG PARA
DETECCIÓN DEL NIVEL DE ATENCIÓN
MEDIANTE WAVELETS**

**Máster Universitario en Sistemas Electrónicos Avanzados.
Sistemas Inteligentes**

Departamento de Electrónica

Presentado por:

D. Fernando Sancho García

Dirigido por:

Dr. D. Rafael Barea Navarro

Alcalá de Henares, a 28 de Junio de 2014



VISTO BUENO DEL DIRECTOR/TUTOR AL TFM

Dr./D. Rafael Barea Navarro

Director/Tutor del Trabajo Fin de Máster de título: Procesado de señal de EEG para detección del nivel de atención mediante Wavelets.

Realizado por D. Fernando Sancho García

Por la presente da su conformidad para que el citado trabajo sea presentado para su defensa

Alcalá de Henares, a 28 de Junio de 2014

Firmado:

Agradecimientos

Primeramente me gustaría agradecer al Departamento de Electrónica de la Universidad de Alcalá y muy especialmente a mi tutor Rafael Barea Navarro por el apoyo y comprensión durante el desarrollo de esta tesis de máster.

También me gustaría agradecer a Laura por su insistencia, apoyo y ayuda sin la cual no hubiese sido posible.

Y por último a mis padres, a los cuales les debo todo. Aun estando lejos sin ellos tampoco hubiera sido posible. Gracias.

Índice

Resumen.....	2
Introducción.....	3
1. Señal de encefalograma.....	4
2. Transformada Wavelet.....	6
3. Redes neuronales.....	9
4. Mindset.....	11
Objetivos.....	13
Desarrollo.....	14
1. Proceso recogida de datos.....	14
1.1. Primer proceso de recogida de datos.....	14
1.2. Segundo proceso de recogida de datos.....	15
1.3. LabWindows y ThinkGear.....	16
2. Presentación de datos.....	17
3. Procesado de señal EEG.....	18
4. Identificación de nivel de atención.....	26
4.1. Redes Neuronales RBF.....	26
4.2. Redes neuronales <i>feed-forward</i>	29
Conclusiones.....	33
Bibliografía.....	35
Anexos.....	37
I. Imágenes IAPS.....	37
II. Videos.....	38

Índice de tablas

Tabla 1: Niveles y frecuencias registrados por <i>Mindset</i>	5
---	---

Lista de imágenes

Imagen 1: Sistema 10-20 de colocación de electrodos con 30 canales. http://www.easycap.de/easycap/e/electrodes/04_M25.htm (Fecha: 24 de Mayo de 2014).	4
Imagen 2: Representación esquemática de la transformada Wavelet.....	7
Imagen 3: Estructura de malla de primer nivel.....	8
Imagen 4: Cálculo de coeficientes de detalle y aproximación hasta nivel 3.....	8
Imagen 5: Esquema general de la red neuronal RBF.	9
Imagen 6: Esquema general de red neuronal <i>feed-forward</i>	10
Imagen 7: Dispositivo <i>Mindset</i> de <i>Neurosky Inc.</i> http://www.technologytell.com/gaming/54753/gdc-2010-neurosky-shows-off-mindset-wave-and-mind-invaders/ (Fecha: 7 de Junio de 2014).	11
Imagen 8: Patrón de visionado para el registro de señales.	15
Imagen 9: Programa para adquisición de datos en <i>Labwindows</i>	16
Imagen 10: GUI para la presentación de datos obtenidos mediante la herramienta <i>Mindset</i> . .	17
Imagen 11: Espectro de frecuencia haciendo uso de la FFT en <i>MATLAB</i>	18
Imagen 12: Visionado de imágenes IAPS mediante GUI en <i>MATLAB</i>	18
Imagen 13: Menú para el cálculo de la transformada Wavelet.....	19
Imagen 14: Representación 3D de la transformada de Wavelet para valores de factor de escala de 1 a 256.....	20
Imagen 15: Niveles de atención y meditación presentados junto a la transformada de Wavelet con factor de escala igual a 42.	21
Imagen 16: Señal en bruto y nivel de la onda delta presentados junto a la transformada de Wavelet con factor de escala igual a 42.....	22
Imagen 17: Niveles de las ondas theta y alpha presentados junto a la transformada de Wavelet con factor de escala igual a 42.	23
Imagen 18: Niveles de las ondas beta y gamma presentados junto a la transformada de Wavelet con factor de escala igual a 42.	24
Imagen 19: Transformada Wavelet para α igual a 42, función base elegida <i>db5</i>	24
Imagen 20: Nivel de atención registrado por <i>Mindset</i> . Máximos para factor de escala 42, representados sobre el nivel de atención.....	25
Imagen 21: Cálculo de transformada Wavelet para α igual a 11 (izquierda). Nivel de atención con máximos para factor de escala 11 (derecha).	25
Imagen 22 : Cálculo de transformada Wavelet para α igual a 26 (izquierda). Nivel de atención con máximos para factor de escala 26 (derecha).	26
Imagen 23: Nivel de atención registrado mediante <i>Mindset</i> y nivel de atención simulado mediante red neuronal RBF, con señal de entrada, la señal en bruto.....	27
Imagen 24: Nivel de atención registrado versus simulado.	28
Imagen 25: Nivel de atención registrado mediante <i>Mindset</i> y nivel de atención simulado mediante red neuronal RBF, con señal de entrada transformada Wavelet con factor de escala igual a 42.	28
Imagen 26: Evaluación del gradiente a lo largo de las diferentes iteraciones, y número de validaciones fallidas (izquierda). Evaluación de los resultados a lo largo de las diferentes iteraciones, tanto para el entrenamiento, validación y test (derecha).	30

Imagen 27: Curvas ROC para los distintos pasos en la definición de la red neuronal para el primer set de datos de entrada.	30
Imagen 28: Matriz de confusión para los resultados obtenidos con el primer set de datos de entrada.	31
Imagen 29: Curva ROC para segundo set de entradas.....	31
Imagen 30: Matriz de confusión para segundo set de datos.....	32

Resumen

Mediante la siguiente tesis de máster se propone el estudio, abstracción y análisis de niveles de atención mediante la señal de EEG (Electroencefalograma) a través de la transformada Wavelet.

El análisis de las señales fisiológicas y su compresión resulta sin duda muy interesante para los llamados interfaces cerebro-ordenador (*BCI-Brain Computer Interfaces*). Y a pesar de la complejidad de las señales registradas, es posible obtener patrones que nos proporcionen información del estado cerebral en cada caso.

En resumen, el propósito de este trabajo de fin de máster es el análisis de las señales de EEG, aplicación de la transformada Wavelet a estas, para un posterior estudio y obtención de un patrón que de manera sencilla nos dé información acerca del estado de atención de la persona.

El proyecto por lo tanto se dividirá en tres etapas: obtención de señales de EEG, tratamiento y procesado de las señales adquiridas y, por último, una evaluación y comprobación de la veracidad de los niveles de atención obtenidos.

Las conclusiones abstraídas de la tesis nos podrían proporcionar información acerca del estado de la persona bajo estudio, tanto de sus emociones, como del nivel de meditación, así como su nivel de atención, el cual, por ejemplo, ha sido previamente utilizado en estudios relacionados con la conducción [1].

A pesar de presentar algunas limitaciones, esta herramienta es sencilla y los datos obtenidos con ella, aunque menos fiables que los obtenidos con otros métodos, son suficientes para realizar un estudio preliminar como éste. Un estudio más exhaustivo precisaría, además, una muestra de individuos de tamaño mayor y con un rango de edad más amplio. De esta manera, sería posible cubrir un mayor espectro de la población y, por lo tanto, abstraer conclusiones más generales.

Introducción

De media el ser humano genera decenas de miles de pensamientos por día y la interacción de las neuronas genera pequeños impulsos eléctricos que pueden ser registrados en el electroencefalograma.

Los últimos avances en la investigación de la interacción persona-ordenador (*HCI-Human Computer Interaction*) han sido enfocados en la comprensión total de las señales fisiológicas humanas, en este caso concreto, nos incumbe las señales que el cerebro genera y que quedan registradas mediante electroencefalogramas.

Con un sinfín de aplicaciones, los ritmos cerebrales nos pueden proporcionar información del estado emocional, nivel de atención ó meditación de la persona bajo estudio.

A pesar de la complejidad y naturaleza de las señales, el estudio de las emociones es sin duda una de las áreas que en los últimos tiempos más se han desarrollado. El hallazgo de patrones en las señales fisiológicas proporcionaría información muy importante con múltiples aplicaciones en diferentes áreas.

Los sistemas de interacción persona-ordenador permite la traducción e interpretación de la actividad electrofisiológica ó metabólica del ser humano, en señales que posteriormente pueden ser utilizadas en ciertos dispositivos.

Centrándonos en las señales cerebrales, las diferentes actividades de un sujeto son procesadas y controladas por diferentes partes del cerebro, así como el control de las extremidades se realiza en el córtex motor, en el lóbulo temporal se realizan las funciones auditivas ó en el lóbulo occipital reside la capacidad de visión. El lóbulo frontal es el relacionado con la atención y motivación del individuo, y por lo tanto la herramienta *Mindset* de *Neurosky Inc.* que proporciona un electrodo en seco en la zona frontal del cráneo parece el más adecuado para el registro de dicha actividad.

Una de las características más importantes en la comunicación diaria en los seres humanos son las emociones. Algunos investigadores centran sus estudios en el entendimiento de las reacciones, aunque en el caso que nos ocupa, como a otros investigadores, puede resultar interesante el estudio de las emociones para la creación de interfaces cerebro-ordenador.

Uno de los centros de estudio de las señales biológicas, y con multitud de estudios relacionados con el análisis de las emociones es el *CSEA (Center for the Study of Emotion and Attention)*. Su trabajo se centra en el estudio de las emociones y su relación con la salud mental y desordenes mentales.

Aunque la mayoría de los estudios de las emociones se basan en otro tipo de señales, como son las señales faciales ó de voz, el análisis de las señales biológicas proporciona una tercera vía, que aunque difícil de procesar, resulta más difícil de fingir, entre las cuales podemos incluir el nivel de atención.

Aunque han existido y existen investigaciones recientes relacionadas con el estudio y reconocimiento de emociones usando no sólo señales biológicas, sino también diferentes

fuentes de datos como: presión arterial, conductancia de la piel, medida de la respiración, etcétera, es ahora cuando se ha producido un incremento en el uso de las señales de EEG.

Por último es importante comentar que diferentes estudios han comprobado que los estímulos visuales junto con sonido provocan mayores estímulos al cerebro [2], lo que en nuestro caso resultó de una gran importancia durante el registro de las señales cerebrales.

1. Señal de encefalograma

El lóbulo frontal está relacionado con la capacidad de entender y actuar hacia un determinado fin del ser humano. Tan solo se encuentra desarrollado en determinados vertebrados y animales complejos.

Se puede decir que en el lóbulo frontal residen nuestras emociones, estados mentales, concentración, en resumen nuestra personalidad. En él se llevan a cabo las funciones ejecutivas, es decir las que permiten comportarnos de una determinada forma, planificar y atender.

Como ya se explicará posteriormente *Mindset* proporciona una lectura de las ondas cerebrales en la posición FP1 del sistema 10-20 de colocación de electrodos para el registro de electroencefalogramas.




Imagen 1: Sistema 10-20 de colocación de electrodos con 30 canales.

http://www.easycap.de/easycap/e/electrodes/04_M25.htm (Fecha: 24 de Mayo de 2014).

De acuerdo con *Mindset* los diferentes ritmos cerebrales pueden agruparse en rangos de frecuencias. En la siguiente tabla se describen los diferentes ritmos cerebrales proporcionados por el dispositivo *Mindset*:

Señal	Frecuencias
Delta	1-3 Hz
Theta	4-7 Hz
Alpha1	8-9 Hz
Alpha2	10-12 Hz
Beta1	13-17 Hz
Beta2	18-30 Hz
Gamma1	31-40 Hz
Gamma2	41-50 Hz

Tabla 1: Niveles y frecuencias registrados por *Mindset*.

En algunos casos las ondas cerebrales han sido divididas por *Mindset* en dos subrangos, debido a que ocupan un mayor espectro de frecuencias. Los valores de los rangos de frecuencia no suelen cambiar dependiendo de los estudios, pero existen algunas diferencias en cuanto a la interpretación de estos ritmos.

Las diferentes ondas cerebrales pueden relacionarse con diferentes estados del ser humano, pero en cada uno de ellos existen unas características que los hacen interesantes para nuestros propósitos.

Los ritmos delta son los de mayor amplitud aunque se relacionan con estados de sueño previos al REM (*Rapid Eye Movement sleep*), también se han podido detectar en actividades en las cuales son necesarios estados de continua atención. Están relacionados con estados hipnóticos ó de meditación. En adultos son predominantes en la zona frontal.

Las ondas theta aunque principalmente se producen con la excitación durante la adolescencia, existen estudios que los relacionan con estados de meditación y periodos creativos.

Las ondas alpha están relacionadas con la relajación, y son mayores cuando mantenemos los ojos cerrados, reduciéndose al abrirlos. Se localiza en la parte posterior de la cabeza en ambos hemisferios.

Los ritmos beta aunque se encuentran en ambos hemisferios cerebrales, son más activos en la parte frontal. Son especialmente altos cuando pensamos activamente ó estamos concentrados en una actividad. Es por ello que se trata uno de los ritmos cerebrales en los que podemos estar interesados.

Por último las ondas gamma se muestran más activas cuando llevamos a cabo pensamientos con interacción motora, y puesto que la herramienta *Mindset* es muy sensible a los movimientos, incluso al parpadeo, las ondas gamma no son las ondas más adecuadas para este estudio.

Podemos concluir que para esta tesis las ondas cerebrales que pueden resultar más interesantes por lo tanto son las ondas theta, alpha y beta, que de alguna forma guardan relación con los momentos en los cuales el ser humano está centrado ó prestando atención.

En función de los niveles registrados para los diferentes ritmos por *Mindset*, este calcula mediante algoritmos los niveles de atención y de concentración de la persona.

Mindset no solo proporciona valores de atención, sino también de meditación, después de atender a sus definiciones resulta claro que en este último caso de la meditación, son las ondas alpha las que resultan más interesantes de analizar e interpretar.

Ciertos estudios han relacionado emociones con el ascenso y descenso en la potencia registrada de la señal alpha [3]. A su vez, también se ha podido comprobar que para determinadas bandas de frecuencias pueden existir cambios en la sincronización de estas dependiendo del estado emocional de la persona, lo cual podría afectar a los resultados.

2. Transformada Wavelet

La transformada de Wavelet presenta múltiples ventajas respecto a otros modelos de análisis para este tipo de señales biológicas.

La transformada Wavelet a diferencia de otras transformadas, proporciona un análisis multiresolución, mediante ventanas dilatadas. El análisis de frecuencias altas se realiza mediante ventanas estrechas, mientras que el análisis de frecuencias bajas se realiza mediante ventanas anchas.

Entre sus principales usos se encuentra el análisis de bioseñales, como en nuestro caso el electroencefalograma, así como de señales sísmicas ó de radar, debido a la potencia de sus características. Así mismo se puede extender la transformada Wavelet en dos dimensiones que puede ser utilizada en el procesamiento, reconocimiento de patrones y compresión de datos.

Como se ha comentado anteriormente, una de las principales características de la transformada Wavelet, es que permite un análisis multiresolución en tiempo y frecuencia, y este dependerá de la elección de la función base.

Las diferentes categorías y tipos de wavelets proporcionan diferentes opciones de análisis para una misma señal bajo examen. Y por lo tanto, dependiendo de las características de la señal a analizar, se elegirá un determinado tipo de función base u otro.

Son varias las ventajas de la transformada Wavelet respecto, por ejemplo a la transformada de Fourier. Trabaja en ambos dominios tiempo y frecuencia. Es más fácil de representar una señal que tiene cambios bruscos ó saltos con Wavelets que con transformadas de Fourier, mejora la compresión de datos, la eliminación de ruido en una señal y por último la complejidad de su cálculo es de menor orden.

Se podría pensar, por ejemplo, en el uso de la transformada de Fourier de tiempo corto (*STFT-Short Time Fourier Transform*), pero resulta imposible un conocimiento preciso de las componentes frecuenciales en un determinado instante de tiempo, pudiéndose explicar con el conocido Principio de Incertidumbre de Heisenberg. Lo mejor que se puede hacer es conocer las componentes espectrales en un intervalo de tiempo, y es por ello que se utiliza la transformada Wavelet en vez de transformada de Fourier, puesto que permite una mayor granularidad.

De forma general, la transformada Wavelet de una función es una descomposición de esa función en un conjunto de funciones, que forman una base. Se trata de la suma a través del tiempo de la señal multiplicada por la función base Wavelet desplazada y diezmada.

La transformada continua de Wavelet puede expresarse mediante la siguiente fórmula:

$$= \text{---} [1]$$

Donde a es el llamado factor de escala, b la traslación en el tiempo y ψ la función base usada para la transformada Wavelet. De los valores elegidos de a y b dependerá la resolución en frecuencia y tiempo.

La transformada Wavelet, como ya se ha comentado anteriormente, tiene diferentes parámetros que deben de tenerse en cuenta. El primero de ellos es la función base, que dependiendo de las características de la señal, debe elegirse una que se asemeje a la señal original, ya que la transformada de Wavelet mide la correlación de las señales, original y Wavelet base. En la transformada Wavelet, el cálculo de sus coeficientes es una medida de lo similar que la señal base es a la señal real para un determinado momento.

Debido a que los cálculos podrían resultar tediosos y de alta carga computacional, el uso de la transformada discreta de Wavelet (*DWT-Discrete Wavelet Transform*) es aconsejable. Por lo tanto se escoge un número finito de valores de a y b , y es por ello que el uso de la base 2 resulta la mejor opción. El término $1/\sqrt{a}$ se debe a la normalización de energía para cada uno de los valores de escala.




Imagen 2: Representación esquemática de la transformada Wavelet.

En la figura anterior se puede comprobar que los diferentes rectángulos conservan la misma área. A mayor frecuencia el muestreo es menor en frecuencia pero mayor en el tiempo, mientras que a menor frecuencia ocurre todo lo contrario.

La transformada Wavelet nos da la correlación entre la función base desplazada y diezmada con respecto a señal, y es por lo tanto especialmente interesante en señales no estacionarias. Proporciona información sobre cuándo y qué frecuencias sufren cambios y la magnitud de estos.

Una de las aplicaciones más interesantes de la transformada discreta de Wavelet es quizás la compresión de datos. Stéphane Mallat desarrolló una teoría para la implementación de la transformada discreta de Wavelet mediante filtros paso bajo (FPB) y paso alto (FPA). Como se ha dicho, es especialmente interesante en la compresión de datos, como por ejemplo imágenes, ya que puede ser implementado en 2 dimensiones. A su vez permite obtener la señal original realizando las operaciones inversas sin una apreciable pérdida de información.

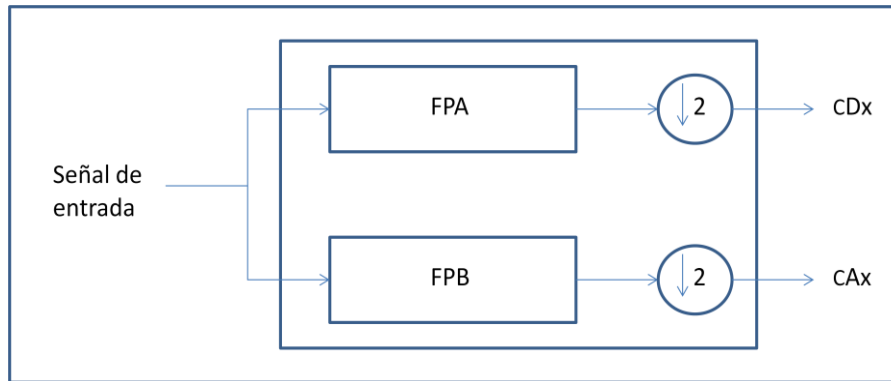


Imagen 3: Estructura de malla de primer nivel.

Tras el paso de la señal por los filtros paso alto y paso bajo se realiza un diezmado de la señal. De esta forma se obtiene un coeficiente de detalle y otro de aproximación respectivamente. La operación se realiza múltiples veces, dependiendo de la resolución deseada, utilizando en general para los siguientes niveles como señal de entrada el llamado coeficiente de aproximación.

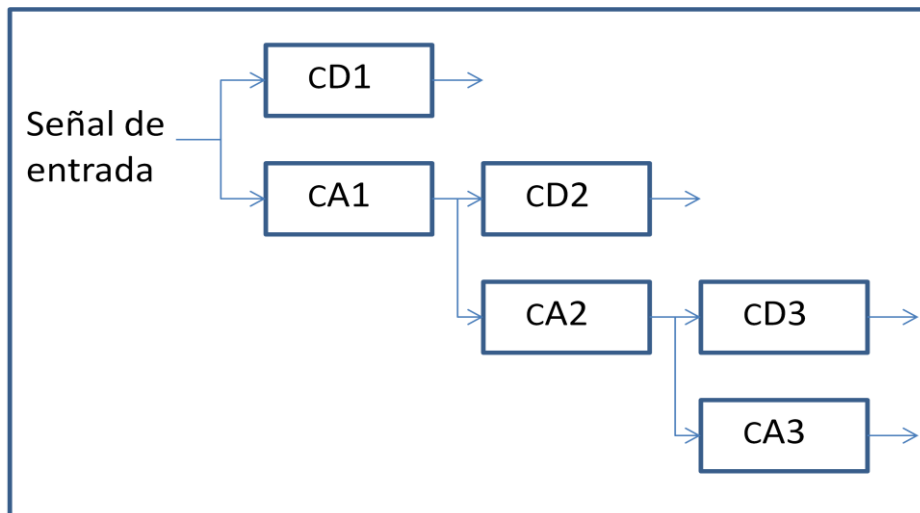


Imagen 4: Cálculo de coeficientes de detalle y aproximación hasta nivel 3.

La razón de utilizar el llamado coeficiente de aproximación como entrada al siguiente nivel se debe a que el coeficiente de aproximación contiene la información de frecuencias más bajas y por lo tanto no es necesario tener una alta resolución en tiempo de esa parte del espectro, mientras que para frecuencias altas los cambios son más rápidos en el tiempo y por lo tanto se necesita una mayor resolución en el dominio del tiempo.

El resultado es similar a la transformada Wavelet, pongamos como ejemplo una señal de EEG. El filtro paso alto de nivel 1 podría filtrar frecuencias en el rango de 25 a 50 Hz. El coeficiente

de aproximación de nivel 1 contiene el espectro de frecuencias en ese rango con la mitad de muestras. El coeficiente de detalle, por su parte, contiene la información del espectro en el rango de 0 a 25 Hz con la mitad de muestras que la señal original. Dicha señal se haría pasar por un filtro paso alto con banda de paso de 12,5 a 25 Hz, y su señal de salida tendría una cuarta parte de las muestras que la señal original, y así sucesivamente.

La idea consiste en almacenar la máxima información con el mínimo de datos. A mayor frecuencia tenemos una mayor resolución en el tiempo puesto que los cambios en la señal son más rápidos, sin embargo para frecuencias bajas los cambios son más lentos y no es necesario un número tan grande de muestras.

Con la descomposición mediante filtros paso alto y paso bajo, las frecuencias altas contienen una mayor resolución en tiempo, mientras que para frecuencias bajas la resolución es mayor en frecuencia.

3. Redes neuronales

Las redes neuronales proporcionan una forma de modelar sistemas complejos no lineales que no son fácilmente representados por una función [4].

Mediante la *toolbox* de *MATLAB* es posible el modelado de redes neuronales desde los diseños más sencillos hasta los más complejos de una red neuronal, modificando el número de nodos, pesos, método de aprendizaje, etcétera.

En un primer caso, nos hemos centrado en las redes neuronales con funciones de base radial (*RBF-Radial Basis Function*), las cuales se definen por tener la salida dependiente únicamente de la distancia al origen u origen desplazado, es decir son simétricas con respecto al origen.

Las redes neuronales de base radial tienen como característica principal que permiten una clasificación no lineal. Las funciones utilizadas tanto en la capa oculta como en la capa de salida son diferentes. En la capa oculta se utilizan las funciones radiales de carácter no lineal, mientras que la capa de salida se dispone de funciones lineales. Además de trabajar mejor con gran volumen de datos de entrenamiento, pero requiere de un mayor número de neuronas en la capa oculta, cuya base radial tiene como parámetros los centros y la anchura de estos, que define la desviación estándar de la campana de Gauss que se utiliza como función radial.

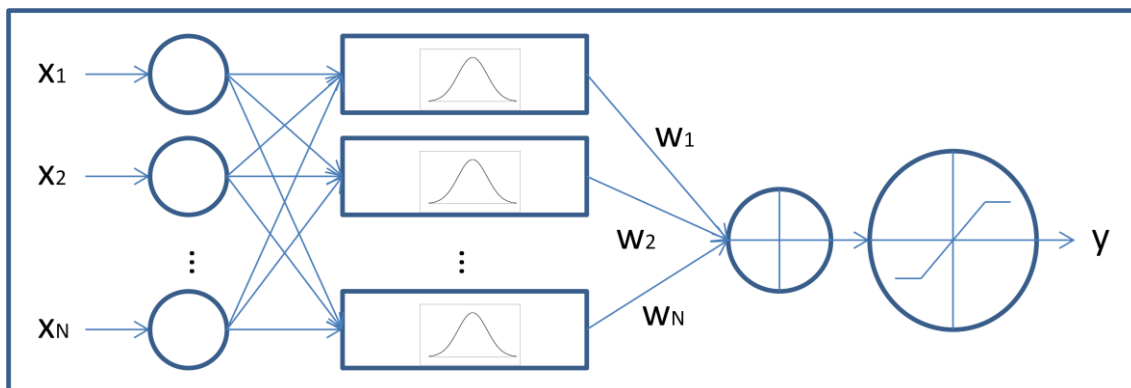


Imagen 5: Esquema general de la red neuronal RBF.

El diseño de la red neuronal consiste en tres pasos diferenciados, inicialización de la red neuronal con los parámetros seleccionados, entrenamiento de la red neuronal y por último la simulación de la red neuronal.

Las aplicaciones de las redes neuronales RBF son varias. Uno de los problemas más comunes en los que las RBF tienen aplicación son la aproximación de funciones ó identificación de sistemas. Mediante pares entradas-salida de una función que se desconoce se desea identificar al sistema que produce tales salidas. Se define por lo tanto la salida de la red neuronal de la siguiente forma:

→

[2]

Donde N define el número de los nodos de la capa oculta, w_i representa el peso de la neurona en la capa de salida y c_i el centro vector del nodo, siendo x el vector de entrada. En nuestro caso se trata de la distancia euclídea, para una sola entrada se trataría de la distancia al centro.

La distancia del vector de entrada con respecto al vector de centros de las funciones radiales supone la entrada a las funciones radiales. Valores cercanos al centro de la función radial tenderán a la unidad mientras que valores alejados de esta tenderán a cero, y a ello se debe que no sea lineal la clasificación.

También se hizo uso de las redes neuronales *feed-forward*, las cuales se utilizan para la clasificación en el problema de reconocimiento de patrones ó en la aproximación de funciones.

Se utiliza en este caso el número de neuronas en la capa oculta como principal parámetro de diseño. Aunque pueden utilizarse diferentes configuraciones, en este caso fue usada una red unidireccional.

Para el entrenamiento de la red neuronal fue seleccionado el método de descenso por el gradiente. La red neuronal tiene el siguiente esquema:

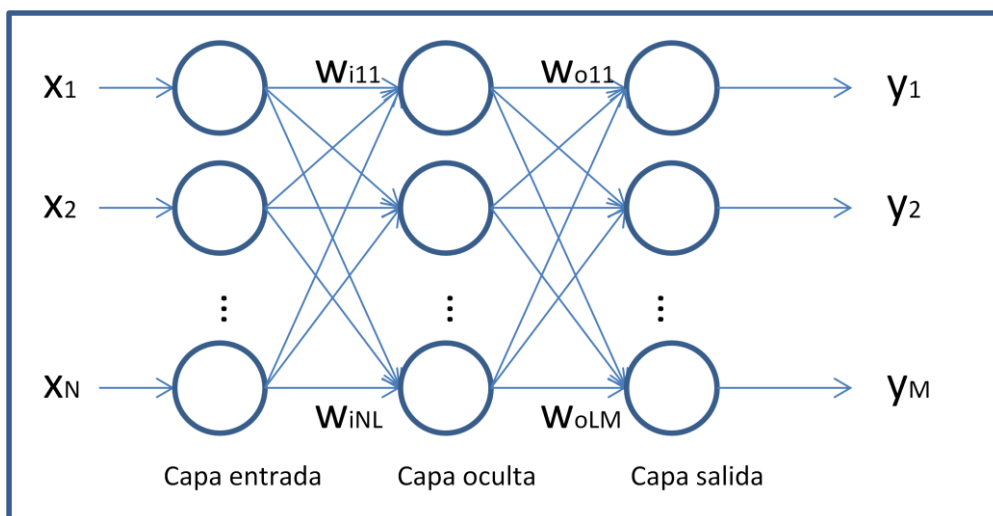


Imagen 6: Esquema general de red neuronal *feed-forward*.

Las redes *feed-forward* utiliza *backpropagation* para el ajuste de los pesos, de manera que se minimice el error entre la salida esperada y la obtenida. Es decir, el método de descenso por el gradiente actualiza los valores de los pesos en función del resultado retroalimentado, minimizando el error medio.

La siguiente formula define el vector de salida para el vector de entrada \mathbf{x} :

$$y_m = \sum_j w_{ojm} \left(\sum_k w_{ikj} x_k \right) \quad [3]$$

Donde los valores de w_{ojm} y w_{ikj} corresponden a los pesos de las neuronas en la capa oculta y entrada respectivamente, mientras que x_k es cada una de los elementos del vector de entrada. La salida consiste en una array de los elementos y_m .

4. Mindset

Mindset de *Neurosky Inc.* proporciona una manera sencilla de obtener señales de electroencefalograma que pueden utilizarse para diferentes aplicaciones. Es una de las múltiples soluciones comerciales para la lectura de señales de electroencefalograma, utilizadas recientemente en múltiples estudios en diferentes centros educativos [5].



Imagen 7: Dispositivo *Mindset* de *Neurosky Inc.* <http://www.technologytell.com/gaming/54753/gdc-2010-neurosky-shows-off-mindset-wave-and-mind-invaders/> (Fecha: 7 de Junio de 2014).

Una de las limitaciones de esta herramienta es la medida de ritmos cerebrales. La toma de la diferencia de potencial, proporciona una derivación, en este caso frontal tomando como referencia el lóbulo de la oreja izquierda. Las dos señales son sustraídas a través de un rechazo al modo común, para servir como único canal del electroencefalograma.

Posteriormente la señal es amplificada con una ganancia de 8000 para mejorar las débiles señales recibidas. Las señales son filtradas mediante filtros analógicos y digitales en el rango de 1 a 50 Hz, puesto que es el rango de frecuencias que incluye ritmos desde delta hasta gamma. Posteriormente se realiza una corrección *anti-aliasing* para, por último, poder seleccionar un muestreo de la señal a 128, 256 ó 512 Hz. En nuestro caso el muestreo de la señal en crudo fue de 512 Hz, puesto que proporciona un mayor número de datos. La documentación menciona que una frecuencia de muestreo de 512 Hz podría no ser exactamente esa, sino ser cercana a un periodo de muestreo de 2 ms, como finalmente haremos en nuestro programa de *LabWindows*.

Cada segundo la señal es analizada tanto en el dominio del tiempo como en el de la frecuencia, para detectar y corregir posibles problemas de ruido, manteniendo la señal original.

El dispositivo *Mindset* proporciona el valor en crudo del encefalograma con el periodo de muestreo seleccionado, mientras que para el resto de ritmos cerebrales y niveles de atención y meditación lo hace cada segundo.

Thinkgear es el nombre que *Neurosky* dio a la tecnología que hace uso del sensor en seco, que permite la medida, amplificación y el análisis de señales de EEG y ritmos cerebrales. *Neurosky* hace uso de sus propios algoritmos para el cálculo del estado mental de la persona que está haciendo uso de la herramienta *Mindset*. Además *Neurosky* proporciona un gran número de aplicaciones y juegos para el entrenamiento de la mente, mediante los niveles de atención y meditación proporcionados por este, y que sirven de ayuda a la hora de comprender el dispositivo.

Como principal ventaja del uso del *Mindset*, es sin duda su protocolo de comunicación y API, que proporciona libertad para implementar la lectura del valor en crudo de la señal de electroencefalograma con el periodo de muestreo seleccionado, mientras que para el resto de ritmos cerebrales, niveles de atención y meditación los valores son calculados cada segundo mediante su algoritmo. Adicionalmente permite la lectura del nivel bajo de señal, ó de batería del dispositivo, así como detección de intensidad de pestañeo, puesto que la cercanía del sensor en la posición FP1 (según el sistema 10-20) al ojo permite la lectura de dicha intensidad.

A diferencia de otros dispositivos ó electrodos en cascos de malla utilizados para la grabación de EEG, instrumentos como *Mindset*, son más cómodos en la colocación y más sencillos de usar.

Mindset llama a cada uno de los niveles medidos *eSense*. Los valores proporcionados de atención y meditación tienen valores comprendidos entre 0 y 100, divididos en diferentes rangos: 0-20 (muy bajo), 20-40 (reducido), 40-60 (neutro), 60-80 (ligeramente elevado) y 80-100 (elevado). Los valores no representan los valores actuales, sino que existe un llamado aprendizaje dinámico, y por lo tanto se adapta mejor, según *Neurosky*, a las fluctuaciones de la actividad cerebral.

En el caso de la señal en bruto, los valores proporcionados por *Mindset* se encuentran dentro del rango de valores que un entero de 16 bits es capaz de dar (-32768 a 32767).

Objetivos

Personalmente el desarrollo de esta tesis de máster supone una inmersión en uno de los campos más interesantes de la ingeniería, cuando la biología y la ingeniería convergen. Así que proporciona un mayor conocimiento y enriquecimiento personal.

En cuanto a un objetivo más global, este proyecto nos proporciona una nueva perspectiva sobre el análisis de las señales de EEG. Se podría decir que la transformada Wavelet ha sido utilizada recientemente en el tratamiento de señales biológicas y su utilización tiene sentido debido a que la naturaleza de las señales de EEG, que son señales que requieren un análisis en ambos dominios, tiempo y frecuencia.

Otro objetivo es aplicar el uso de las redes neuronales para la abstracción del comportamiento de la herramienta *Mindset*, que proporciona valores corroborados de atención y meditación, y así entrenar, simular y verificar resultados aproximados de atención mediante el visionado de imágenes estandarizadas para este tipo de propósitos.

Desarrollo

Esta tesis de máster consiste en el registro de señales de encefalograma, mientras se estimula la actividad cerebral mediante el uso de métodos estandarizados de activación.

Se utilizaron dos métodos diferentes para provocar cambios en los niveles de atención de las diferentes personas que formaron parte del estudio, para posteriormente analizar dichas señales.

Primeramente se propuso el uso de imágenes IAPS (*International Affective Picture System*), las cuales se dividen en tres tipos diferentes de imágenes: agradables, desagradables y neutras (*pleasant*, *unpleasant* y *neutral*). Conforman un conjunto de estímulos emocionales estandarizados para el estudio de los niveles de atención y concentración [7].

Para ello se llevo a cabo una selección de imágenes aleatoria que proporcionase durante un periodo de tiempo suficiente señales encefalográficas. La visualización de dichas imágenes se realizo a su vez siguiendo un determinado patrón estandarizado.

También se realizó el registro de señales mediante un segundo proceso, siempre usando como dispositivo para el registro el *Mindset* de *Neurosky*. Se utilizaron dos anuncios llamativos que provocasen a los sujetos de estudio niveles de atención suficientemente altos y con cambios temporales en ellos. Debido a que el primer tipo de estímulos requería de mucho tiempo de procesamiento de datos, se decidió utilizar anuncios de aproximadamente 40 segundos, que no requiriesen de una alta carga de cálculo.

Para el procesamiento de datos offline se hizo uso de un ordenador portátil con procesador Intel i5 2,53 GHz y 4 GB de memoria RAM.

1. Proceso recogida de datos

El proceso de recogida de datos, debido a que estamos interesados en el encefalograma, consiste en la estimulación del cerebro, en este caso visual, y de esta forma obtener los ritmos cerebrales.

Como se ha comentado anteriormente, durante el proyecto se llevo a cabo dos procesos de recogida de datos, cada uno con diferente estímulo durante el proceso de adquisición y diferente duración, aunque ambos visuales.

Se seleccionó en ambos casos como sujeto para la recogida de datos a personas con edades comprendidas entre los 24 y 27 años. Los sujetos de estudio tenían una visión perfecta ó casi perfecta y no habían tomado ninguna medicación que afectase a la medida del EEG.

Se situó a los sujetos aproximadamente un metro de distancia de la pantalla, en una habitación aislada de forma que ningún otro estímulo interfiriese durante la adquisición de datos.

1.1. Primer proceso de recogida de datos

El primer proceso de adquisición de datos se realizo con la exposición del sujeto a una serie de imágenes siguiendo un patrón de visionado, pertenecientes al IAPS.

Se mostraron dos secuencias cada una de 45 imágenes, elegidas aleatoriamente y con un número equivalente de imágenes pertenecientes a los distintos grupos de imágenes de la base de datos IAPS: 15 agradables (*pleasant*), 15 desagradables (*unpleasant*) y 15 neutras (*neutral*).

La secuencia de visionado fue la siguiente para cada una de las imágenes:



Imagen 8: Patrón de visionado para el registro de señales.

Se mostró al principio del video un ejemplo de forma que el sujeto entendiese la secuencia. Las imágenes IAPS conforman un conjunto de estímulos emocionales estandarizados para el estudio de los niveles de atención y de meditación, aparte de otras muchas aplicaciones, por lo que resulta vital para producir el resultado esperado que el sujeto no haya visionado las imágenes previamente.

El patrón de visionado se basa en trabajos anteriores [7]. La primera imagen, una cruz sobre fondo blanco y duración 2 segundos sirve como indicador de que una nueva imagen va a ser mostrada. La segunda imagen del patrón y perteneciente a la base de datos IAPS, se visionará durante 6 segundos, y por último una línea vertical gris sobre fondo blanco (neutra) durante 15 segundos que permite al sujeto una auto-valoración de la imagen, aunque este caso no se realizó.

El visionado se realizó en dos partes, con 45 imágenes cada parte, y una duración de 17 minutos y 15 segundos cada una de las partes.

1.2. Segundo proceso de recogida de datos

Tras el primer proceso, se decidió que el registro de datos durante un largo periodo de tiempo podría tener ciertas desventajas. Podrían provocar que los niveles de atención proporcionados por *Mindset* no representasen el estado real del sujeto. Como es sabido, si el proceso de adquisición de datos resulta tedioso y repetitivo es posible que la persona de la cual se esté realizando el registro de ondas cerebrales, pueda perder interés sobre lo que se está realizando. Así mismo el registro de muestras durante aproximadamente 17 minutos genera, con una frecuencia de muestreo de 500 Hz, cerca de 510000 muestras, y por lo tanto una alta carga computacional en el procesado de estas.

En este segundo proceso se mostraron dos anuncios televisivos (Anexo II), de aproximadamente un minuto y treinta segundos aproximadamente.

Al final de la visualización de cada uno de los videos, se pregunto a cada sujeto por el momento el cual capto mayor su atención, para realizar una comparación con los niveles proporcionados por la herramienta *Mindset*, aunque no se llego a ninguna conclusión clara.

1.3. LabWindows y ThinkGear

Haciendo uso de la API proporcionada por *Neurosky Inc.*, es posible la comunicación entre el programa implementado en C en *LabWindows* y el dispositivo *MindSet*. El casco lector envía mediante bluetooth las lecturas realizadas al ordenador.

El programa abre una nueva conexión al puerto serie donde el dispositivo bluetooth ha sido conectado y haciendo uso de la API proporcionada por *Neurosky*, somos capaces de leer datos emitidos por el *Mindset*.

Labwindows nos permite lanzar una interfaz gráfica donde somos capaces de ajustar determinados parámetros que nos resultarán interesantes a la hora de analizar los datos adquiridos.

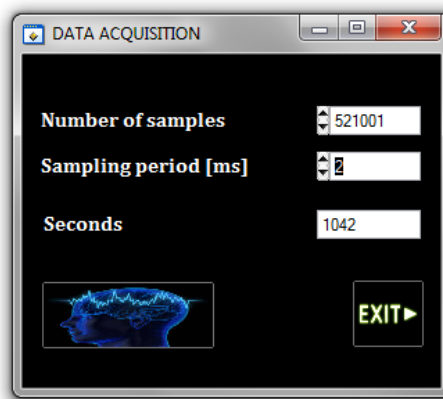


Imagen 9: Programa para adquisición de datos en *Labwindows*.

Ajustando el número de muestras y el periodo de muestreo, conocemos la duración de adquisición y por lo tanto podemos ajustarla a la duración del video ó secuencia de imágenes en su caso.

El programa activa la auto lectura y realiza una lectura continua hasta que el número de muestras recibidas coincide con el número de seleccionadas. *LabWindows* realiza una lectura de todos los valores proporcionados por el dispositivo *Mindset* y los datos son almacenados en un fichero “.dat” siguiendo el siguiente formato, definido para esta tesis de máster:

```
RAW DELTA THETA ALPHA1 ALPHA2 BETA1 BETA2 GAMMA1 GAMMA2 ATTENTION MEDITATION  
BLINK STRENGTH POOR SIGNAL BATTERY
```

39

```
117 66194 25757 2402 13084 5439 4330 1492 949 66 44 0 0 0
```

La primera línea sirve de guía en el caso de que se necesite editar el fichero. Son cada uno de los valores que proporciona *Mindset* y que serán registrados en cada columna. El siguiente valor corresponde a un número aproximado de segundos que duró la adquisición. A continuación los valores recibidos y correspondientes a cada una de los ritmos cerebrales, para cada muestra.

2. Presentación de datos

Se creyó oportuno realizar una pequeña aplicación para la presentación de datos de forma que fuese más sencillo el estudio de las señales recibidas y procesadas. Para ello se hizo uso de la *toolbox* para GUI (*Graphical User Interface*) de *MATLAB*. Siendo el resultado el siguiente:

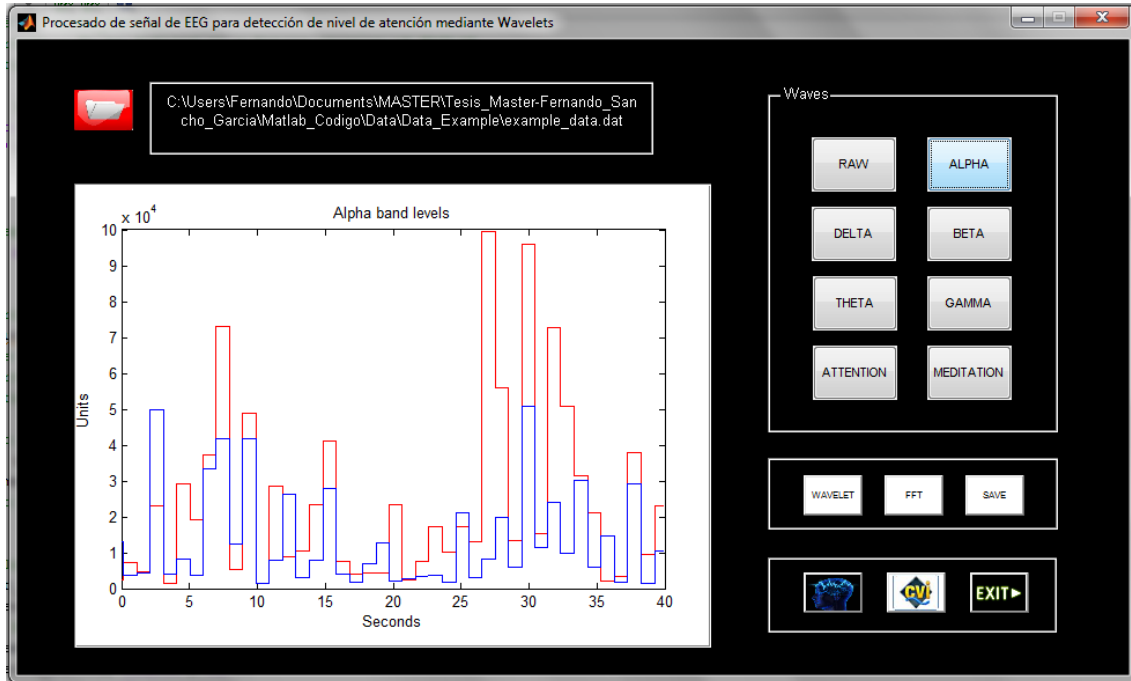


Imagen 10: GUI para la presentación de datos obtenidos mediante la herramienta *Mindset*.

La interfaz gráfica divide los datos almacenados en el fichero “.dat” y muestra los diferentes ritmos cerebrales en función del tiempo. La interfaz gráfica permite realizar cinco operaciones a parte de mostrar las diferentes ondas cerebrales: visionado de la FFT (*Finite Fourier Transform*) de la señal, guardar los datos que han sido procesados en un fichero “.mat”, visionado de videos y registro de datos en paralelo, y por último registro de ondas cerebrales.

El desarrollo de este proyecto implica la obtención de medidas de electroencefalograma y una herramienta que permita su posterior procesado, y para ello se hizo uso de la herramienta *MATLAB* de *Mathworks*, con su *Wavelet toolbox*, como una primera aproximación a la transformada Wavelet.

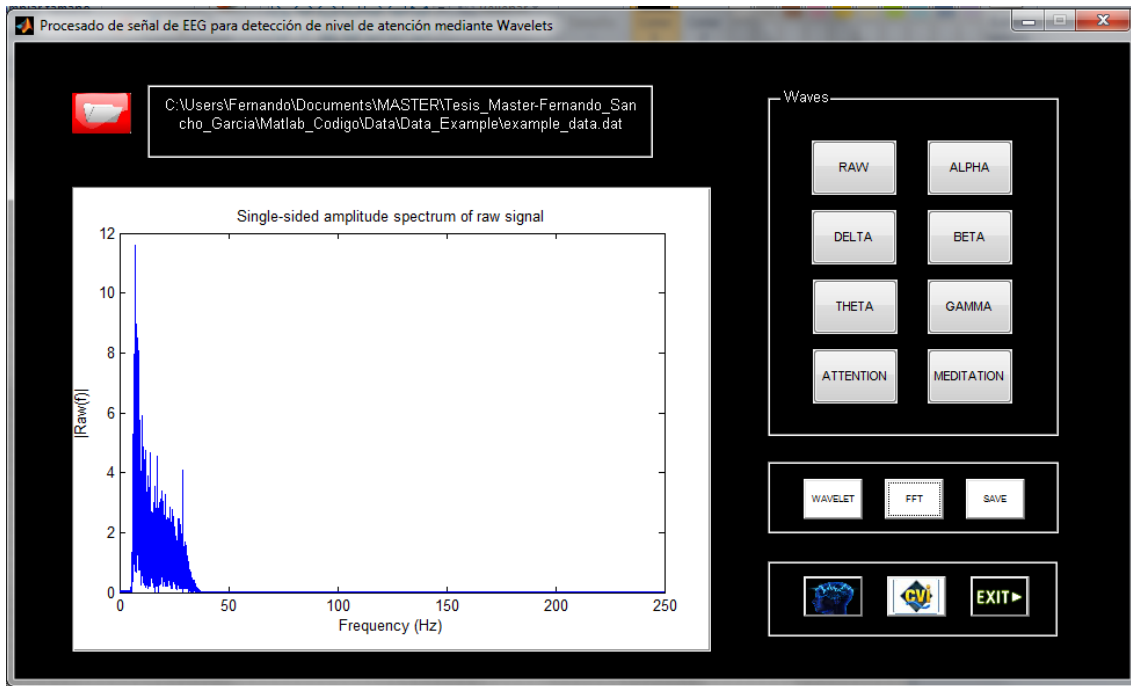


Imagen 11: Espectro de frecuencia haciendo uso de la FFT en MATLAB.

La herramienta de presentación permite a su vez el visionado conjunto de las imágenes IAPS y el registro de la señal mediante el programa implementado en *LabWindows*.

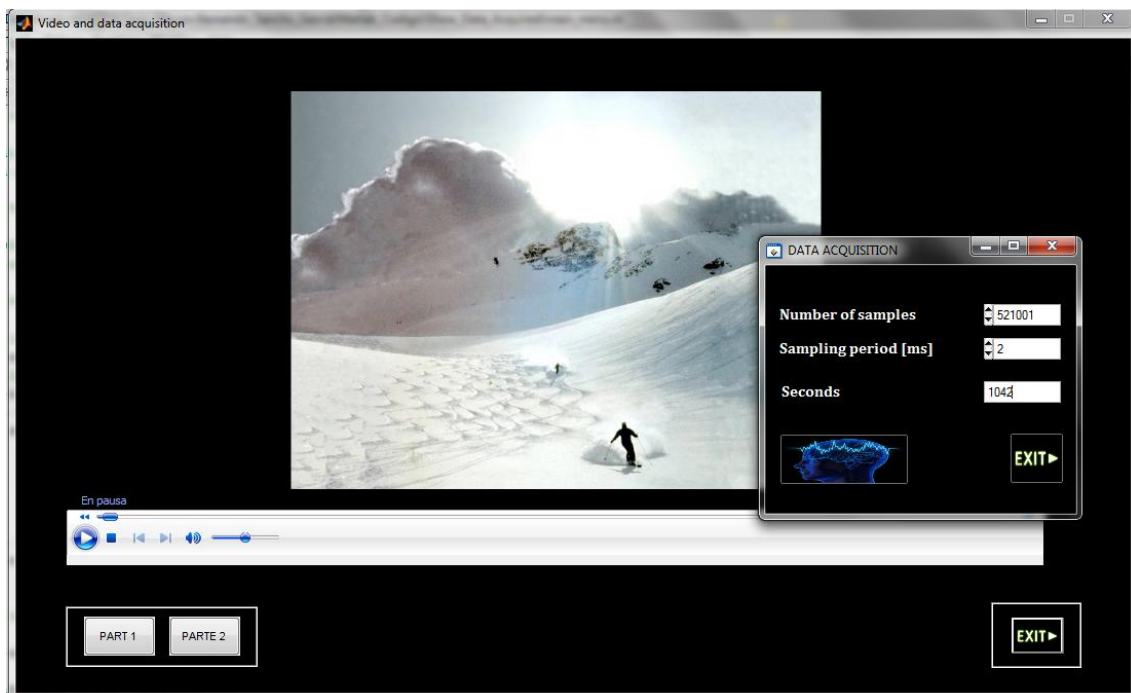


Imagen 12: Visionado de imágenes IAPS mediante GUI en MATLAB.

3. Procesado de señal EEG

La señal, como ya se ha mencionado previamente, se muestreó a una frecuencia de 500 Hz. Puesto que *Mindset* nos da la posibilidad de obtener la señal encefalográfica con una frecuencia aproximada de muestreo de 512 Hz.

En un principio se optó por un filtrado simple usando un filtro paso banda *Chebyshev* tipo II y orden 5, puesto que no añade ningún rizado en la banda de paso y en la banda eliminada el rizado introducido es igual en toda la banda. La banda de paso en este caso fue 5-40 Hz puesto que los ritmos cerebrales en los cuales estamos interesados pertenecen a esas bandas, aunque el dispositivo *Mindset* de por si proporciona un filtrado de la banda de ritmos cerebrales presentados en la tabla 1. El uso del filtro de *Chebyshev* nos permite eliminar determinadas frecuencias indeseadas. El retraso de grupo introducido por el filtro no es importante ya que una vez filtrada la señal se calcula los coeficientes de wavelet de la señal y es seleccionado uno de los coeficientes, aquel cuya representación en frecuencia es más cercana a la frecuencia seleccionada en el menú de visionado de la transformada Wavelet.

Se realiza un cálculo simple de la llamada pseudo-frecuencia, mediante la siguiente fórmula:

$$F_o = \frac{F_c}{a} \quad [4]$$

Donde F_c es la frecuencia central de la función base de wavelet (por ejemplo para *db2* esta tiene un valor de 0,6667 Hz), que se puede obtener mediante la función en *MATLAB* *centfrq*. T_s es el valor del periodo de muestreo de la señal, y a es cualquier valor dentro de los posibles del factor de escala. La frecuencia F_o representa la pseudo-frecuencia.

Si en el cálculo de la transformada de Wavelet hacemos fijo el valor de a (factor de escala), podremos visualizar la variación de la señal para una determinada frecuencia, la cual es la pseudo-frecuencia para dicho valor de a .

El interfaz gráfico permite seleccionar valores de a entre 2, 4, 8, 16, 32, 64, 128 y 256. La transformada de Wavelet es calculada para K entre 1 y el valor seleccionado con incrementos de la unidad.

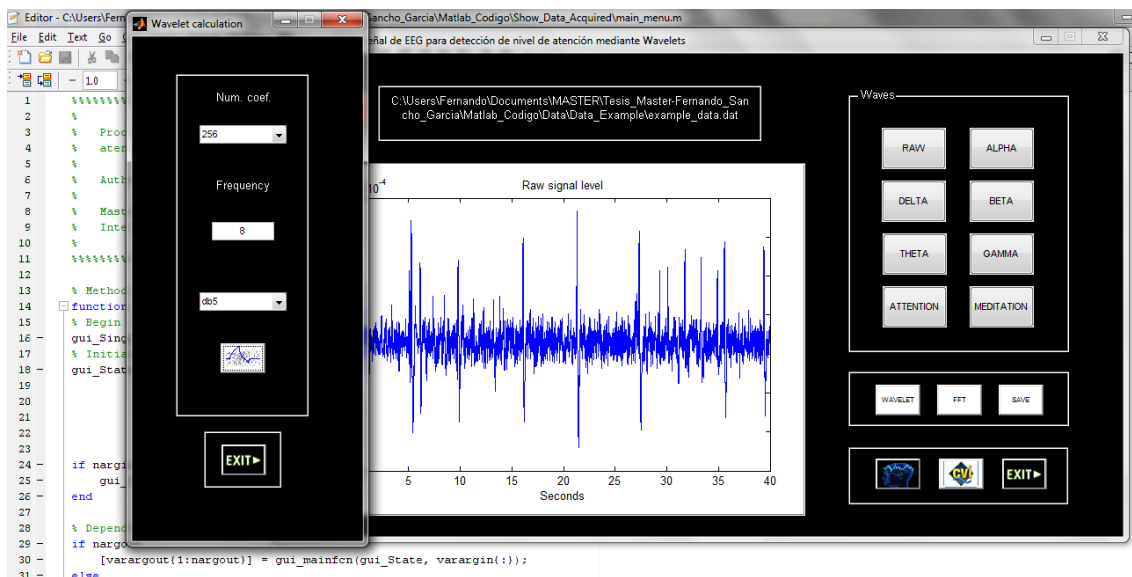


Imagen 13: Menú para el cálculo de la transformada Wavelet.

Como se puede comprobar en los resultados en 3D las frecuencias altas, aunque con una mayor resolución, tiene muy poco peso en la señal debido, especialmente, a que las señales de EEG proporcionadas por *Mindset* no tienen frecuencias por encima de 40 Hz.

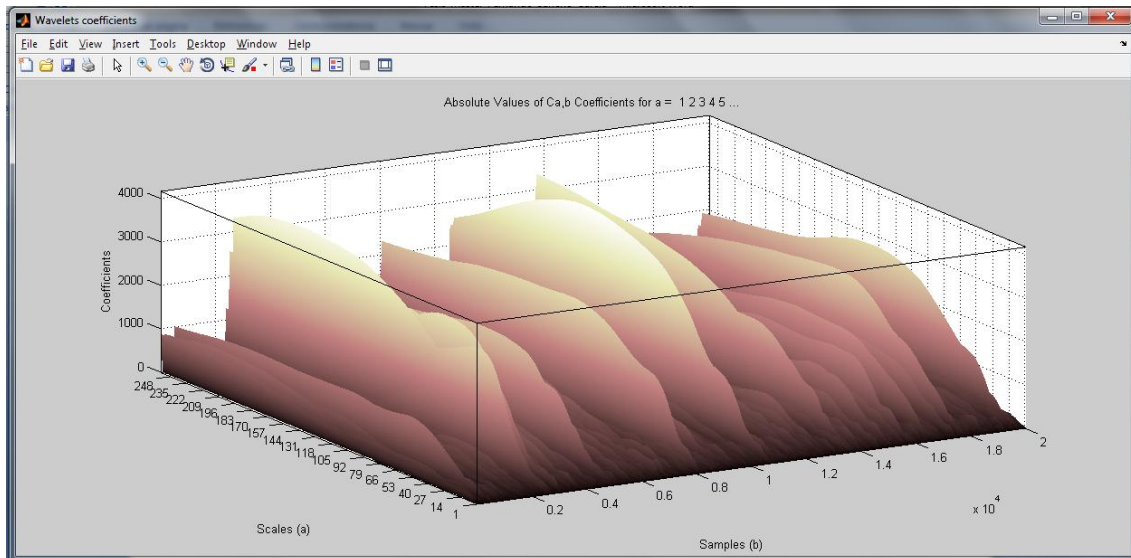


Imagen 14: Representación 3D de la transformada de Wavelet para valores de factor de escala de 1 a 256.

Pongamos como ejemplo los valores límites para el rango 1 a 256. Para a igual a 1, el cálculo de la transformada de Wavelet representaría los cambios a través del tiempo de frecuencia 333,5 Hz, mientras que para a igual 256, representarían los cambios en el dominio del tiempo de la frecuencia 1,30 Hz (para función base Wavelet $db2$).

Por lo tanto, los valores altos de a representan frecuencias bajas, mientras que valores bajos representan frecuencias altas. Como se puede comprobar en la figura 14, los valores bajos de a para valores normalizados de energía representan una pequeña parte de la energía total de la señal en comparación con los valores altos (frecuencias altas).

Los valores altos del factor de escala representan un mayor espectro de frecuencias que los valores bajos de este. Es decir, que la resolución para frecuencias bajas es mayor que para frecuencias altas. En este caso resulta idóneo ya que la señal de EEG ha sido filtrada con una banda de paso de 1 a 40 Hz.

El interfaz gráfico permite la selección de la frecuencia a analizar de la señal de EEG. Es decir, el programa calcula el valor del factor de escala (a) que más se aproxime su valor de pseudo-frecuencia al valor de frecuencia deseada.

Pongamos como ejemplo el ritmo cerebral theta, el cual resulta de interés para nuestros propósitos. Seleccionamos por ejemplo la frecuencia 8 Hz, dentro de la banda theta. Escogemos 256 como pasos de escala, siendo los pasos en el tiempo, el periodo de muestreo. Si la función Wavelet base seleccionada es $db5$, obtendremos el valor a igual a 42, el más próximo a la frecuencia deseada. La transformada Wavelet para a igual a 42 a lo largo del tiempo se muestra junto a los diferentes niveles proporcionados por *Mindset*.

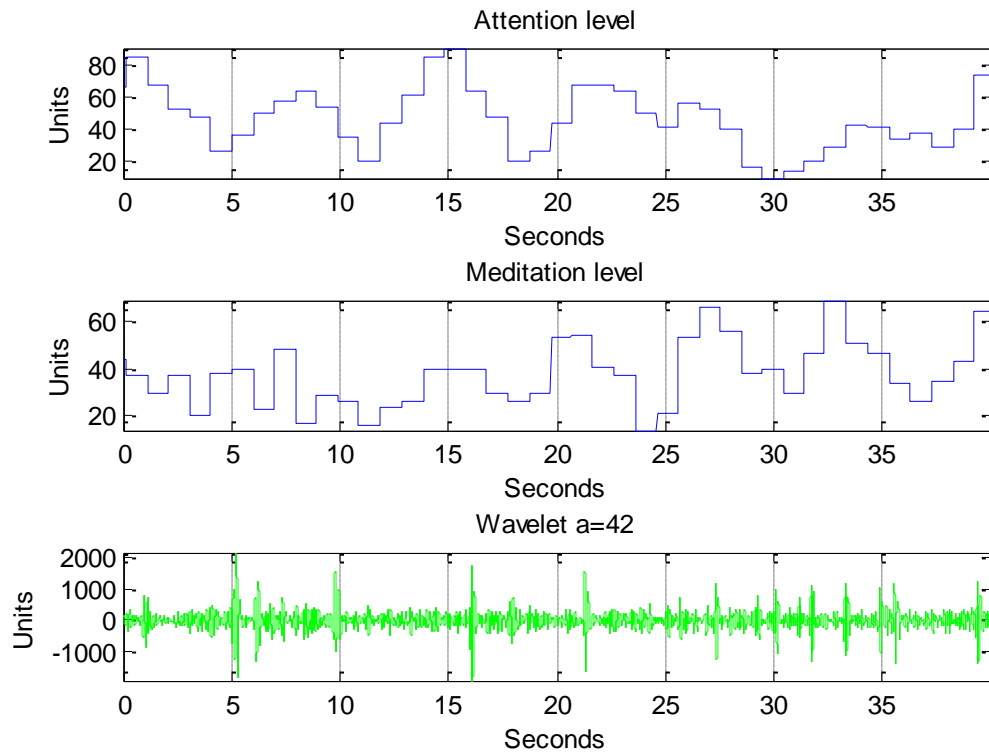


Imagen 15: Niveles de atención y meditación presentados junto a la trasformada de Wavelet con factor de escala igual a 42.




Imagen 16: Señal en bruto y nivel de la onda delta presentados junto a la trasformada de Wavelet con factor de escala igual a 42.

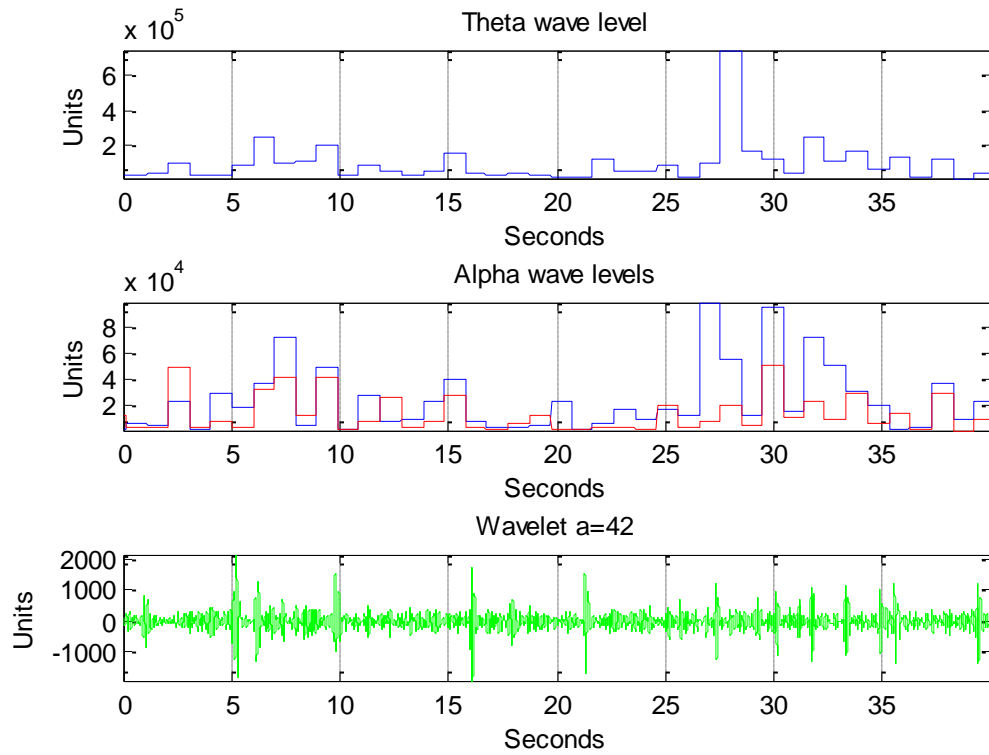


Imagen 17: Niveles de las ondas theta y alpha presentados junto a la transformada de Wavelet con factor de escala igual a 42.

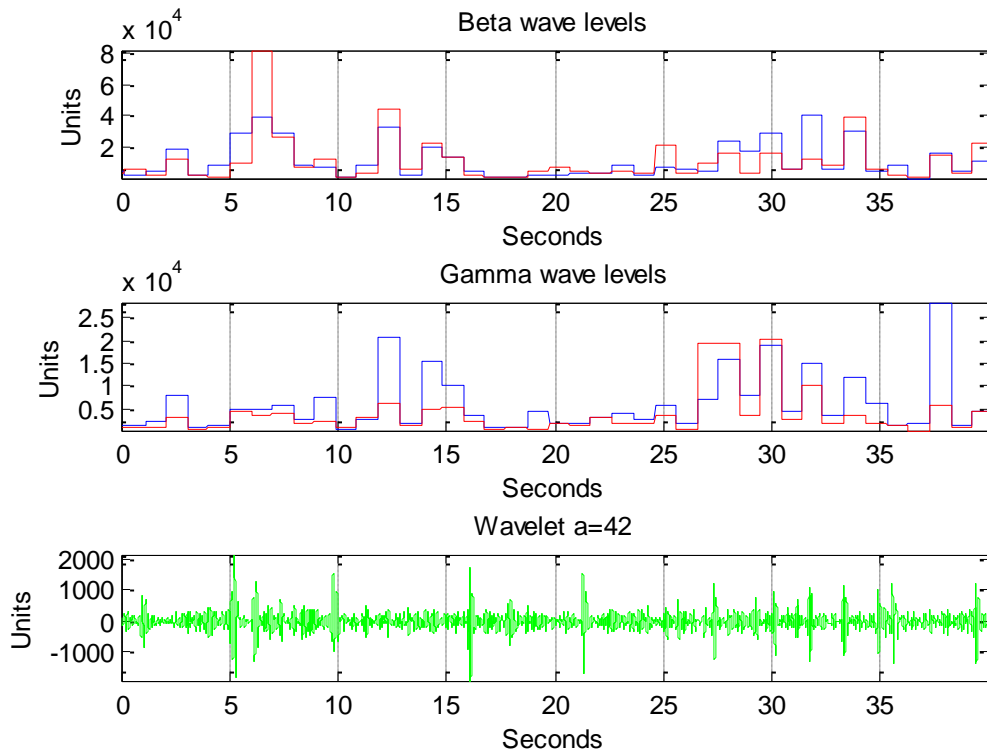


Imagen 18: Niveles de las ondas beta y gamma presentados junto a la transformada de Wavelet con factor de escala igual a 42.

La siguiente figura muestra la localización de los máximos para la transformada de Wavelet con factor de escala igual a 42.

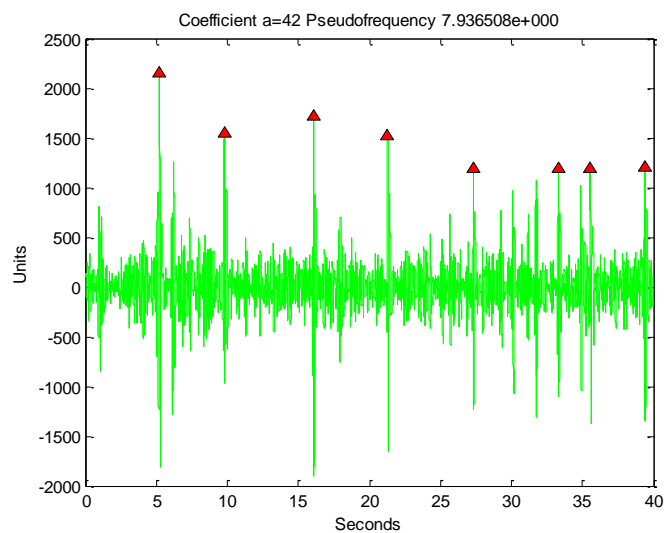


Imagen 19: Transformada Wavelet para a igual a 42, función base elegida *db5*.

En este caso el llamado coeficiente 42 nos da información de cuando se producen los cambios en dicha frecuencia, cuando se produce la máxima actividad y por lo tanto en que instante estos se producen.

Como se puede comprobar los picos para el valor de escala 42 que se encuentran por encima del 55% del máximo coinciden en el tiempo aproximadamente con los picos en la señal de atención proporcionada por *Mindset*.

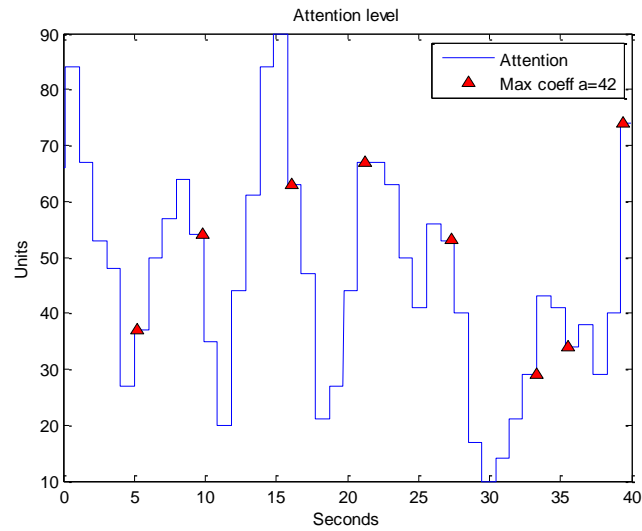


Imagen 20: Nivel de atención registrado por *Mindset*. Máximos para factor de escala 42, representados sobre el nivel de atención.

Como se ha expuesto en la introducción, la banda alpha comienza en los 8 Hz aproximadamente la cual está relacionada con el inicio de periodos de creatividad, los cambios en la actividad para una determinada frecuencia pueden significar cambios por lo tanto en la actividad cerebral, en este caso un aumento en los niveles de atención.

A continuación se muestra los mismos resultados para frecuencias de valor 30 Hz y 12 Hz respectivamente.




Imagen 21: Cálculo de transformada Wavelet para a igual a 11 (izquierda). Nivel de atención con máximos para factor de escala 11 (derecha).




Imagen 22 : Cálculo de transformada Wavelet para a igual a 26 (izquierda). Nivel de atención con máximos para factor de escala 26 (derecha).

Como se puede comprobar los valores de factor de escala menores producen señales de mayor frecuencia y al contrario. Los unidades de las señales presentadas no resultan importantes pero si lo que representan las señales.

Existe una pequeña variación en valores de frecuencia cercanos a 8 Hz, pero de similares resultados. El valor de 55% del máximo como valor umbral fue calculado mediante ensayo y error.

4. Identificación de nivel de atención

Se propuso el uso de las redes neuronales para la identificación de los niveles de atención que fueron registrados con *Mindset*. Se utilizaron tanto redes neuronales RBF como *feed-forward* como se expone a continuación.

4.1. Redes Neuronales RBF

Primeramente se diseñó la red neural, usando como señales de entrada la señal en bruto del EEG, y como salida los valores del nivel de atención registrados. Es importante remarcar que el dispositivo *Mindset* posee algoritmos de aprendizaje que intentaremos no simular sino obtener similares resultados en cuanto a máximos ó picos en el nivel de atención.

Haciendo uso de la función *newrbe* para el diseño de la red, que pretende la obtención de la red neuronal RBF exacta, y utilizando la función *sim* para la simulación de esta, no se obtuvieron los valores esperados del nivel de atención.

Para el entrenamiento de la red neuronal se hizo uso de un 10% de las muestras registradas mientras que para la simulación de la red obtenida se usó el 90% restante, debido a que de otra manera se hace imposible su ejecución, debido su alta carga computacional.

En primer lugar fue elegida como señal de entrada a la red neuronal la señal del encefalograma en bruto.

Seguidamente fue utilizada la señal obtenida de la transformada Wavelet de la señal original, para un valor de factor de escala de 42. Similar a la variación a lo largo del tiempo para la componente de frecuencia de aproximadamente 8 Hz de la señal.

Se obtuvieron los siguientes resultados para los niveles de atención registrados con el *Mindset* y los obtenidos mediante la red neuronal RBF:

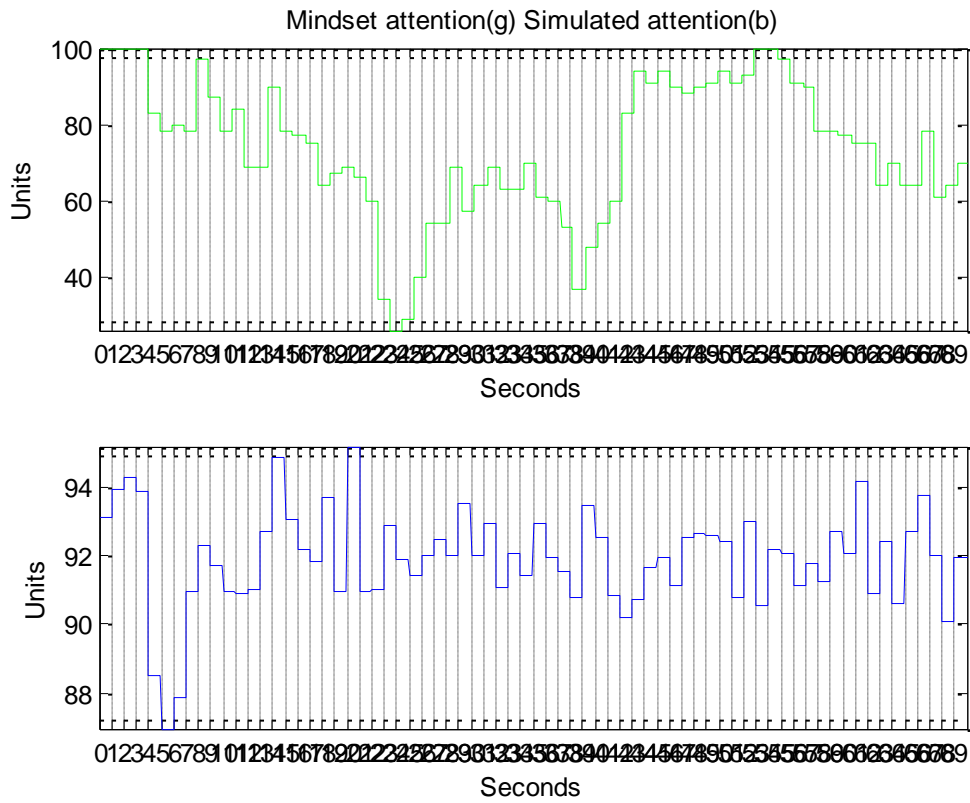


Imagen 23: Nivel de atención registrado mediante *Mindset* y nivel de atención simulado mediante red neuronal RBF, con señal de entrada, la señal en bruto.

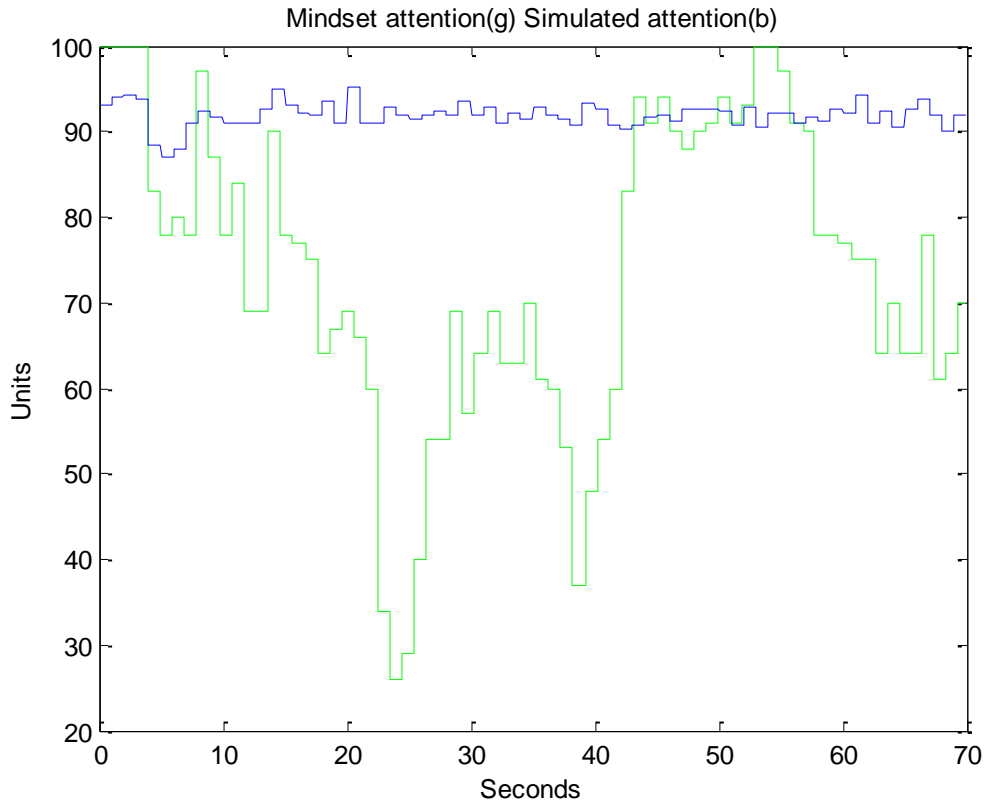


Imagen 24: Nivel de atención registrado versus simulado.

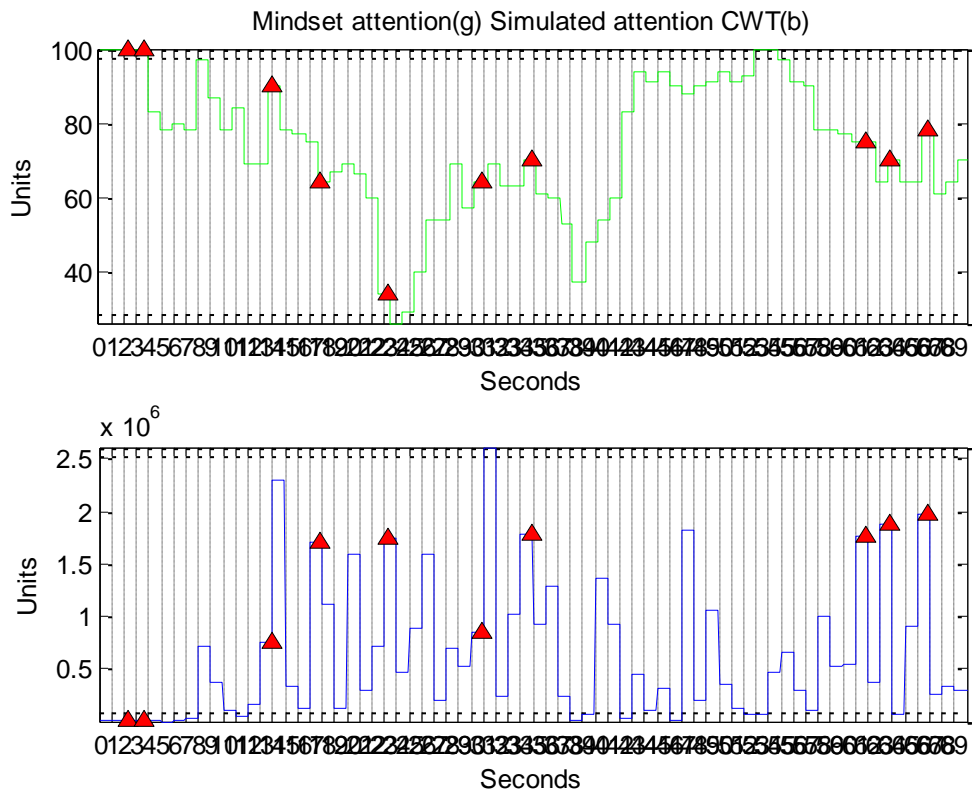


Imagen 25: Nivel de atención registrado mediante Mindset y nivel de atención simulado mediante red neuronal RBF, con señal de entrada transformada Wavelet con factor de escala igual a 42.

Como se puede comprobar para este último intento de simulación del nivel de atención mediante la transformada Wavelet, la red neuronal no converge, por lo que los valores distan de los esperados.

4.2. Redes neuronales *feed-forward*

Haciendo uso de la *toolbox* de *MATLAB* para el diseño de redes neuronales, se puede comprobar de qué manera afectan los diferentes parámetros que podemos modificar en el diseño de esta.

La GUI *nprtool* de *MATLAB* permite el diseño de redes neuronales *feed-forward* para clasificación en el problema de reconocimiento de patrones. Se comprobó que el número de neuronas de 20 en la capa oculta proporcionaba un resultado más aproximado al deseado.

Las redes neuronales *feed-forward* son más rápidas en cuanto al entrenamiento y simulación en comparación con las RBF.

Los valores del nivel de atenuación registrados se dividieron en cuatro sub-rangos, dependiendo de los valores: de 0 a 25, de 25 a 50, de 50 a 75 y por último de 75 a 100. De esta forma realizamos una clasificación más sencilla en función de la atención. La salida de la red será por lo tanto un matriz 4x1 de ceros con un uno en la posición del sub-rango detectado.

Se utilizaron diferentes sets de entradas para la red neuronal. Desde la señal en bruto, a los registros de los ritmos alpha, los registros de los ritmos beta e incluso se utilizó como conjunto de señales de entrada todos los ritmos cerebrales proporcionados por *Mindset*.

Para los diferentes tipos de entradas, se siguió el mismo proceso. Primeramente fue usado *nprtool* para el cálculo del valor más apropiado del número de neuronas de la capa oculta, en este caso 20, y del porcentaje del número de muestras utilizado para el entrenamiento (70%), validación (15%) y test (15%).

Posteriormente se realizó el diseño y entrenamiento de la red neuronal *feed-forward*, haciendo uso de registros obtenidos durante el visionado de imágenes, y la red obtenida, se simuló con los datos registrados durante otro visionado de las imágenes IAPS, para el mismo sujeto.

Usando como datos de entrada todos los ritmos cerebrales a excepción de los ritmos gamma, obtenidos mediante *Mindset*, los resultados fueron los siguientes:

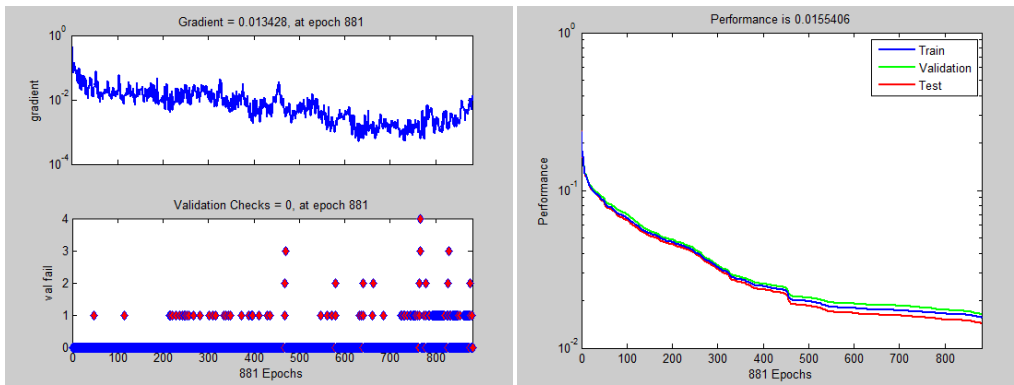


Imagen 26: Evaluación del gradiente a lo largo de las diferentes iteraciones, y número de validaciones fallidas (izquierda). Evaluación de los resultados a lo largo de las diferentes iteraciones, tanto para el entrenamiento, validación y test (derecha).

En este caso el algoritmo de entrenamiento utilizado fue el *trainscg* (*Scaled Conjugated Gradient Backpropagation*), el cual es el más comúnmente utilizado en redes *feed-forward*. Normalmente el método utilizado para la finalización del entrenamiento, consiste en alcanzar un número determinado de validaciones erróneas, en este caso fueron 6.

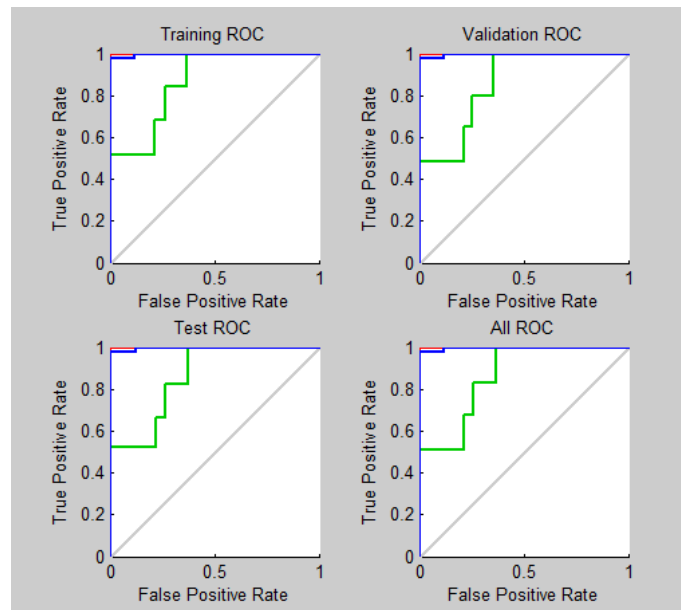


Imagen 27: Curvas ROC para los distintos pasos en la definición de la red neuronal para el primer set de datos de entrada.

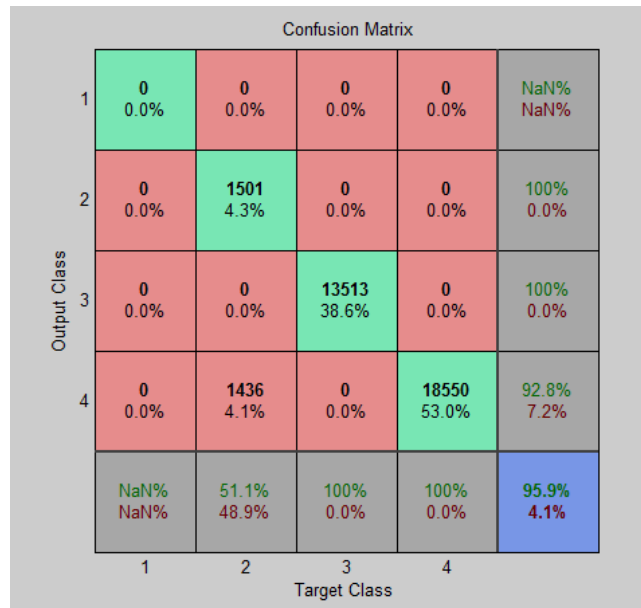


Imagen 28: Matriz de confusión para los resultados obtenidos con el primer set de datos de entrada.

Como se puede comprobar, la red neuronal presenta unos valores razonablemente buenos en cuanto a clasificación de los diferentes rangos de atención para las entradas presentadas. Como se ha comentado anteriormente el experimento fue dividido en dos set de imágenes, y durante la preparación del experimento se paró la adquisición de datos del *Mindset* y por lo tanto la sincronización del dispositivo. Los datos presentados arriba corresponden al primer set de imágenes. Una vez definida la red, se simularon en dicha red los valores registrados para el segundo set de imágenes del mismo sujeto, y se pudo comprobar que aunque interesantes los valores no son los esperados.




Imagen 29: Curva ROC para segundo set de entradas.

Confusion Matrix

Output Class	1	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
	2	6864 1.3%	13263 2.5%	5457 1.0%	496 0.1%	50.9% 49.1%
	3	29721 5.7%	86790 16.7%	75759 14.5%	28573 5.5%	34.3% 65.7%
	4	19146 3.7%	86646 16.6%	110686 21.2%	57600 11.1%	21.0% 79.0%
		0.0% 100%	7.1% 92.9%	39.5% 60.5%	66.5% 33.5%	28.1% 71.9%
		1	2	3	4	
		Target Class				

Imagen 30: Matriz de confusión para segundo set de datos.

En general los resultados obtenidos en la representación de la curva ROC (*Receiver Operating Characteristic*) y por lo tanto de falso positivos pueden ser diferentes en cada ejecución debido a las condiciones iniciales, pero principalmente dependen del número de neuronas, y del algoritmo utilizado para el aprendizaje. En este caso, puesto que para el segundo proceso de adquisición se desconectó el dispositivo *Mindset*, significó un nuevo proceso de aprendizaje del dispositivo para la obtención de los valores de atención, y por lo tanto la utilización de diferentes sets de registros para el entrenamiento y simulación, podría afectar a los resultados.

El plano donde se representa la curva ROC, queda dividido en dos hemisferios. Cuanto más cerca estén los valores de las curvas ROC sobre dicha recta divisoria, más aleatorios serán los valores obtenidos. Cuanto más alejada la curva ROC se encuentre en el plano superior de la recta divisoria, mejores los valores de clasificación serán.

Los valores obtenidos distan de los esperados pero dan idea de las posibilidades ofrecidas por las redes neuronales para la clasificación de las señales de electroencefalograma obtenidas mediante *Mindset*.

Se comprobó que haciendo uso de la señal en bruto de encefalograma ó la señal en bruto multiplicada por si misma de forma que eliminásemos los términos negativos y centrarnos en los máximos de la señal, los resultados fueron peores que los presentados previamente, puesto que la red no llegó ni siquiera a converger.

Conclusiones

El desarrollo de esta tesis de máster me ha permitido entre otras cosas una inmersión en un tema tan de actualidad como es el análisis de señales biológicas y su posterior procesado.

Es importante remarcar que en el análisis de señales biológicas, es necesario un conocimiento previo de la materia.

La mayoría de los estudios realizan la adquisición de datos usando un conjunto alto de canales, mientras que con el uso de *Mindset* existe la limitación en el número de estos.

Es necesario comentar que tanto las actividades relacionadas con un determinado ritmo cerebral y los rangos de frecuencia de estos pueden variar ligeramente dependiendo del autor, y por lo tanto es necesario analizar las conclusiones obtenidas del trabajo, aunque en general los valores utilizados suelen ser estandarizados.

Son varios los factores que influyen en los resultados obtenidos, algunos de ellos se han comentado previamente:

- Las señales obtenidas mediante *Mindset* tienen la limitación de ser una solución comercial, y por lo tanto la señal registrada puede resultar diferente de la obtenida mediante una solución más científica.
- Los algoritmos para la abstracción de los niveles ó ritmos cerebrales son soluciones propias de *Mindset* y aunque han sido utilizadas en diferentes universidades y organizaciones, no significa que se puedan abstraer a unas conclusiones más generales.
- Los ritmos cerebrales proporcionados por *Mindset* son valores adaptativos. Es decir, el dispositivo va adaptándose a los cambios en las ondas para cada individuo en particular, por lo que sacar conclusiones generales es bastante difícil.

Aunque en un primer momento se pensó que el uso de imágenes IAPS resultaba más correcto para la justificación de valores obtenidos, puesto que se trata de estímulos estandarizados, se pudo comprobar que a la hora de procesado de la señal, registros más cortos de EEG resultaban más útiles, debido a las limitaciones de computación.

La realización de una aplicación para la presentación de los datos resulto interesante a la hora de analizar los diferentes tipos de función base Wavelet y el número de pasos en el factor de escala.

La transformada Wavelet proporcionó un análisis interesante de la señal en ambos dominios, tiempo y frecuencia. Aunque se utilizó un número alto de diferentes valores de factor de escala, se pudo comprobar que para frecuencias bajas, no existe un cambio tan evidente.

En cuanto a las redes neuronales utilizadas, se puede concluir que se obtuvo los mejores valores usando como señales de entrada un array de registros de los diferentes niveles proporcionados por *Mindset*. Aunque una vez entrenada y simulada la red, no pudo utilizarse para simular con otro registro de señales, incluso pertenecientes a un mismo sujeto. Como se ha comentado anteriormente el algoritmo adaptativo de *Mindset*, no da un valor concreto de

atención sino un valor adaptado a la señal de encefalograma registrada para cada momento. Una vez desconectado ó sin contacto del Mindset en la zona frontal de la cabeza, el dispositivo reinicia ese proceso de aprendizaje.

Aparte de todo lo explicado en esta memoria se realizaron diferentes experimentos para obtener un resultado concluyente pero por limitación de tiempo no se pudo lograr. Además de todo lo comentado fue necesaria una familiarización con el dispositivo *Mindset*, *LabWindows* y con los diferentes *toolbox* de *MATLAB* que quizás limiten el tiempo de implementación.

Los siguientes pasos a seguir serían ampliar el rango de personas bajo estudio, y el uso de nuevas herramientas para el registro de EEG. Los valores de la transformada de Wavelet deberían ser contrastados con otros estudios del nivel de atención, y compararlos con los valores obtenidos mediante *Mindset*, para de esa forma, obtener unas conclusiones más generales.

Bibliografía

- [1] Zhao QiBin, Zhang LiQing & Cichocki Andrzej, "EEG-based asynchronous BCI control of a car in 3D virtual reality environments", *Science China Bulletin*, vol. 53, January 2008.
- [2] M. Murugappan, R. Nagarajan and S. Yaacob, "Combining Spatial Filtering and Wavelet Transform for Classifying Human Emotions Using EEG Signals", *Journal of Medical and Biological Engineering*, vol. 31, no. 1, pp. 45-51, 2011.
- [3] K. Schaaff and T. Schultz, "Towards Emotion Recognition from Electroencephalographic Signals". University of Karlsruhe (TH), Karlsruhe, Germany, 2009.
- [4] Redes Neuronales Toolbox, Matlab, Mathworks.
- [5] Neurosky, Inc. <http://www.neurosky.com>.
- [6] Lang, P.J., Bradley, M.M., & Cuthbert, B.N. (2008). International affective picture System (IAPS): Affective ratings of pictures and instruction manual. Technical Report A-8. University of Florida, Gainesville, FL.
- [7] The Center for the Study of Emotion and Attention. University of Florida. <http://www.csea.php.ufl.edu>.
- [8] K. H. Kim, S. W. Bang and S. R. Kim, "Emotion recognition system using short-term monitoring of physiological signals", *Medical & Biological Engineering & Computing 2004*, vol. 42, pp. 419-427, 2004.
- [9] M. Murugappan, M. Rizon, R. Nagarajan and S. Yaacob, "FCM clustering of Human Emotions using Wavelet based Features from EEG", *Biomedical Soft Computing and Human Sciences*, vol. 14, no. 2, pp. 35-40, 2009.
- [10] M. Murugappan, M. Rizon, R. Nagarajan, S. Yaacob, I. Zunaidi and D. Hazry, "Emotions using FCM and FKM," *International Journal of Computers and Communications*, issue 2, vol. 1, pp. 21-25, 2007.
- [11] Mohamed Rizon, "Discrete Wavelet Transform Based Classification of Human Emotions Using Electroencephalogram Signals," *American Journal of Applied Sciences 7 (7)*, pp. 878-885, 2010. ISSN 1546-9239.
- [12] M. Li and B. L. Lu, "Emotion Classification Based on Gamma-band EEG".
- [13] R. Khosrowabadi, H. C. Quek, A. Wahab and K. K. Ang, "EEG-based emotion recognition using self-organizing map for boundary detection," in *2010 International Conference on Pattern Recognition*, pp. 4242-4245, 2010.

- [14] M. Murugappan *et al*, "Classification of human emotion form EEG using discrete wavelet transform," *J. Biomedical Science and Engineering* 3, pp. 390-396, 2010.
- [15] M. Murugappan, R. Nagarajan and S. Yaacob, "Classifyng Human Emotions Using EEG Signals," *Journal of Medical and Biological Engineering*, vol. 31, no. 1, 2011.
- [16] J. H. L. Hansen, "Recording Situated Human Communications," in *2007 IEEE Automatic Speech Recognition and Understanding Workshop*, December 2007.
- [17] T. Kim, D. Shin and D. Shin, "Towards an Emotion Recognition System based on Biometrics," in *2009 International Joint Conference on Computational Sciences and Optimization*, pp. 656-659, 2009.
- [18] N. van Galen and H. van Zandbrink, "Emotion Detection Using EEG Analysis". Delf University of Technology, Delf, Holland.
- [19] Physionet. The research resource for complex physiologic signals. <http://physionet.org>.

Anexos

I. Imágenes IAPS

Las imágenes utilizadas para el visionado en la adquisición de datos de la base de datos IAPS fueron las siguientes:

1340, 1440,1441, 1450, 1460, 1710, 1750, 1810, 1930, 2040, 2070, 2150, 2190, 2341,2345, 2360, 2393, 2655, 2703, 2800, 3000, 3010, 3053, 3064, 3068, 3071, 3080, 3100, 3110, 3120, 3130, 3140, 3225, 3261, 3400, 3530, 4002, 4220, 4250, 4599, 4641, 4694, 5500, 5520, 5530, 5600, 5621, 5626, 5720, 5731, 5833, 7000, 7004, 7006, 7010, 7020, 7031, 7035, 7036, 7040, 7041, 7050, 7060, 7080, 7090, 7110, 7150, 7175,7233, 7234, 7361, 7705, 7900, 7950, 8120, 8180, 8190, 8461, 8490, 8497, 9040, 9181, 9250, 9254, 9300, 9410, 9433, 9570, 9920, 9921.

II. Videos

Video 1: Volkswagen, "The Force: Volkswagen Commercial." *Youtube*. Youtube, 2 de Febrero de 2011. Web. 7 de Junio de 2014.

Video 2: Axe, "AXE Shower Gel - Funny Commercial" *Youtube*. Youtube, 4 de Mayo de 2007. Web. 7de Junio de 2014.

