

**Universidad Central “Marta Abreu” de Las Villas**

**Facultad de Ingeniería Eléctrica**

**Centro de Estudios de Estudios de Electrónica y Tecnologías de  
la Información (CEETI)**



## **TRABAJO DE DIPLOMA**

### **Reconocimiento de potenciales evocados visuales utilizando Transformada Wavelet y Redes Neuronales BP**

**Autor: Dayron Zayas Daniel**

**Tutor: MS.C. Ing. Idileisy Torres Rodríguez**

**Santa Clara**

**“Año 57 de la Revolución”**

**"2015"**

**Universidad Central “Marta Abreu” de Las Villas**

**Facultad de Ingeniería Eléctrica**

**Centro de Estudios de Estudios de Electrónica y Tecnologías de  
la Información (CEETI)**



## **TRABAJO DE DIPLOMA**

### **Reconocimiento de potenciales evocados visuales utilizando Transformada Wavelet y Redes Neuronales BP**

**Autor: Dayron Zayas Daniel**

[dzayas@uclv.edu.cu](mailto:dzayas@uclv.edu.cu)

**Tutor: MS.C. Ing. Idileisy Torres Rodríguez**

[itrodriguez@uclv.edu.cu](mailto:itrodriguez@uclv.edu.cu)

**Santa Clara**

**“Año 57 de la Revolución”**

**"2015"**



Hago constar que el presente trabajo de diploma fue realizado en la Universidad Central “Marta Abreu” de Las Villas como parte de la culminación de estudios de la especialidad de Ingeniería en Biomédica, autorizando a que el mismo sea utilizado por la Institución, para los fines que estime conveniente, tanto de forma parcial como total y que además no podrá ser presentado en eventos, ni publicados sin autorización de la Universidad.

---

Firma del Autor

Los abajo firmantes certificamos que el presente trabajo ha sido realizado según acuerdo de la dirección de nuestro centro y el mismo cumple con los requisitos que debe tener un trabajo de esta envergadura referido a la temática señalada.

---

Firma del Tutor

---

Firma del Jefe de Departamento  
donde se defiende el trabajo

---

Firma del Responsable de  
Información Científico-Técnica

## **PENSAMIENTO**

Cuida tus pensamientos porque se volverán palabras. Cuida tus palabras porque se volverán actos. Cuida tus actos porque se harán costumbres. Cuida tus costumbres porque forjarán tu carácter. Cuida tu carácter porque formará tu destino. Y cuida tu destino porque será tu vida.

## **DEDICATORIA**

A mis padres, por toda su abnegación, por ayudarme y apoyarme en todos los momentos, por el sacrificio que realizaron y que realizan para que pueda terminar mis estudios, por su comprensión, por enseñarme a ser una mejor persona cada día, por el ejemplo que me han inspirado a seguir.

¡A mi familia, de todo corazón!

## **AGRADECIMIENTOS**

Para la confección de esta tesis he recibido la ayuda y colaboración de muchas personas sin las que no hubiese sido posible realizarla. Por tanto les doy las gracias infinitas a todos los profesores que con tanta dedicación me han transmitido sus conocimientos a través de todos estos años, a mi tutora Idisleisy Torres Rodríguez que ha estado presente en todo momento que la he necesitado. A mis padres y hermana, mis tías, a mi familia en general. A los amigos que han compartido conmigo durante los últimos cinco años, a mis amigos de Morón que siempre estuvieron y estarán en las buenas y en las malas. Gracias por todo de corazón.

## TAREA TÉCNICA

- Realización de un estudio sobre las características importantes de los Potenciales Evocados.
- Búsqueda, selección y organización de una Base de Datos de Potenciales Evocados que permita la realización del experimento.
- Detección Potenciales Evocados usando Transformada Wavelet.
- Reconocimiento de los Potenciales Evocados detectados usando Redes Neuronales BP.
- Evaluación de los resultados obtenidos.

---

Firma del Autor

---

Firma del Tutor

## RESUMEN

Las interfaces computadora cerebro (BCI) han obtenido auge en las últimas décadas, permitiendo una forma distinta de comunicación entre los sistemas, los cuales usualmente son controlados por el lenguaje o las acciones físicas. Los equipos controlados por el cerebro usando las señales Electroencefalográficas proveen de una nueva forma de comunicación para las personas. Los Potenciales Evocados son señales bioeléctricas producto de la actividad que se presenta en las zonas neurales, periférica y central, como respuesta a estímulos externos. El reconocimiento de estos potenciales utilizando algún tipo de método puede proveer de una señal de control a un sistema BCI. En este trabajo se realiza la selección de rasgos usando transformada wavelet para entrenar un Red Neuronal con algoritmo de entrenamiento *Backpropagation*. Usando una wavelet madre *coif4* para la descomposición de la señal, una data balanceada y una red neuronal con función de entrenamiento 'trainrp' y 20 neuronas en la capa oculta se obtiene una tasa promedio de exactitud en la clasificación del 96,3 %.

## TABLA DE CONTENIDOS

PENSAMIENTO .....	i
DEDICATORIA .....	ii
AGRADECIMIENTOS .....	iii
TAREA TÉCNICA .....	iv
RESUMEN .....	v
INTRODUCCIÓN .....	9
Organización del informe .....	11
<b>CAPÍTULO 1.    DETECCIÓN Y RECONOCIMIENTO DE POTENCIALES EVOCADOS</b> 12	
1.1.    Potenciales Evocados .....	12
1.1.1.    Potenciales Evocados Visuales .....	14
1.1.2.    Potenciales Evocados P300 .....	15
1.2.    Promediado Coherente .....	18
1.3.    Características basadas en transformada wavelet .....	20
1.3.1.    Transformada Wavelet (TW) .....	20
1.3.2.    Transformada wavelet discreta (DWT) .....	22
1.3.3.    Análisis multiresolución .....	23
1.4.    Diferenciación de respuesta a estímulos <i>target</i> y <i>no-target</i> .....	23

1.5. Técnicas de clasificación para BCI basadas en el uso del deletreador con P300	
24	
1.5.1. Método de correlación Pearson.....	24
1.5.2. Discriminante Linear de Fisher.....	24
1.6. Redes Neuronales .....	25
1.7. Conclusiones del Capítulo.....	28
<b>CAPÍTULO 2. MATERIALES Y MÉTODOS.....</b>	<b>29</b>
2.1 Características de la base de datos .....	29
2.2 Organización de la Data .....	30
2.3 Preprocesamiento de los datos .....	33
2.4 Transformada Wavelet y selección de coeficientes .....	34
2.5 Clasificación de señales <i>target</i> y <i>no target</i> con Redes Neuronales BP.....	38
2.5.1 Herramienta <i>nprtool</i> .....	39
2.5.2 Matriz de confusión.....	40
La matriz de confusión contiene información sobre el porcentaje de datos que fueron correctamente / incorrectamente clasificados. La matriz de confusión contiene número de casos que:.....	40
2.5.3 Curva ROC .....	42
2.5.4 Creación de la red y entrenamiento .....	43
2.6 Conclusiones del Capítulo.....	46
<b>CAPÍTULO 3. RESULTADOS Y DISCUSIÓN .....</b>	<b>47</b>
3.1 Obtención de coeficientes utilizando transformada discreta wavelet. ....	47
3.2 Señales obtenidas mediante promediado y reconstrucción wavelet. ....	50
3.3 Clasificación utilizando redes neuronales.....	51
<b>CONCLUSIONES Y RECOMENDACIONES .....</b>	<b>58</b>

Conclusiones .....	58
Recomendaciones .....	58
REFERENCIAS BIBLIOGRÁFICAS .....	60
ANEXOS .....	66
Anexo I Valores RMS de la señal reconstruida con cuatro wavelet madres diferentes ...	66

## INTRODUCCIÓN

Las interfaces computadora cerebro han obtenido auge en las últimas décadas, permitiendo una forma distinta de comunicación entre los sistemas, los cuales usualmente son controlados por el lenguaje o las acciones físicas. Los equipos controlados por el cerebro usando las señales Electroencefalográficas proveen de una nueva forma de comunicación para las personas. Las primeras investigaciones sobre interfaces cerebro - computadoras (BCIs, *de sus siglas en inglés*) datan de la década de los 70, en la Universidad de Los Ángeles, California (UCLA) [1]. Desde entonces, el campo de la investigación y el desarrollo BCIs se ha centrado primariamente en las aplicaciones de neuroprótesis, principalmente las encargadas de restaurar los daños en el oído, la vista y el movimiento. Gracias a la sorprendente plasticidad cortical del cerebro, las señales de las prótesis implantadas pueden, después de una adaptación, ser manejadas por el propio cerebro como un sensor natural [1].

Existen distintas técnicas de BCI. Dentro de las técnicas no invasivas se encuentra el uso de Potenciales Evocados (PE). Específicamente las investigaciones relacionadas con las ondas P300 [2]. El potencial evocado P300 se utiliza en muchos sistemas BCI porque es una respuesta típica e ingenua a una opción deseada. El diseño de BCI incluye entre sus requerimientos la rapidez del sistema, este requerimiento de velocidad sugiere usar otras técnicas para la detección del PE que no sea el promediado coherente, el cual necesita de un número grande de épocas a promediar con el objetivo de alcanzar una buena Relación Señal a Ruido (SNR, *de sus siglas en inglés*) [3]. En varias referencias bibliográficas se sugiere el uso de la transformada *wavelet* [3-4] [5] con el objetivo de reducir el ruido y detectar el PE. La transformada *wavelet* permite además, el análisis de la señal electroencefalografía (EEG) considerado ruido de fondo en el análisis de los PE, con el objetivo de detectar

formas de ondas transientes semejantes a los *spikes*, ondas presentes en la señal EEG producto al suceso de episodios epilépticos. Permite además la extracción de características que pueden ser usadas en la clasificación de diferentes señales [5].

Diferentes técnicas de reconocimiento de patrones son usadas en la detección de señales específicas del cerebro [6]. Técnicas como Redes Neuronales [7-12], Máquinas de Soporte Vectorial [13-14], Modelos ocultos de *Markov* [15-16], se usan en el desarrollo de BCI. Las Redes Neuronales usando *Backpropagation* fueron usadas por primera vez en [17] para el reconocimiento rápido de la forma del potencial, proveyendo así que la red neuronal pueda ser usada para clasificar la señal EEG y usada en el desarrollo de BCI.

A pesar de que en la bibliografía existen varios métodos de detección y clasificación de PE, con el objetivo de mejorar el desarrollo de BCI, el estudio de estas técnicas complementa la formación de un Ingeniero Biomédico, el cual debe conocer y profundizar en los principios y métodos fundamentales empleados en los sistemas y tecnologías biomédicas para el diagnóstico y la terapéutica médica actualizándolo sobre las principales técnicas usadas con este fin en el mundo [18]. El tema posee novedad teórica, los conocimientos adquiridos pueden ser aplicados en las asignaturas de Procesamiento Digital de Señales y Procesamiento Digital de Señales Avanzado, tanto en pregrado como en postgrado. Actualmente el CEETI cuenta con proyectos de investigación vinculados al Centro de Neurociencias de Cuba (CNEURO) donde esta área de investigación pudiese contribuir. A pesar de todo lo planteado existen limitantes para desarrollar investigaciones de este tipo, no se cuentan con Bases de Datos que permitan el desarrollo de la investigación, y con muy pocas referencias sobre el tema en nuestro país. Lo antes planteado sugiere formularse la siguiente **pregunta**, ¿Es posible el reconocimiento de PE usando redes neuronales que han sido detectados previamente usando transformada wavelet? Para dar respuesta a esta interrogante se plantea el siguiente **objetivo general**: Detectar y Reconocer Potenciales Evocados utilizando Transformada Wavelet y Redes Neuronales BP usando alguna Base de Datos reportada en la bibliografía para el desarrollo de BCI. Los diferentes **objetivos específicos** que permitirán el desarrollo de este tema son enumerados a continuación.

1. Seleccionar la Base de Datos de Potenciales Evocados con la que se realizará el experimento mediante búsqueda bibliográfica.

2. Organizar la data de forma tal que permita la detección de los Potenciales Evocados.
3. Detectar los Potenciales Evocados mediante Transformada Wavelet.
4. Reconocer los Potenciales Evocados detectados usando Redes Neuronales BP.

### **Organización del informe**

El informe consta de Introducción, tres capítulos, bibliografía y anexos.

El Capítulo 1 denominado Detección y Reconocimiento de Potenciales Evocados, recoge algunas características relevantes de los Potenciales Evocados, especialmente los Potenciales Evocado Visuales y Cognitivos, que pueden ser determinantes para la clasificación de si se está presente una respuesta a un estímulo o no. Se describen muy someramente algunas técnicas de detección de PE, como el Promediado Coherente y la Transformada Wavelet. Además de mencionar algunos métodos propuestos en la literatura para la clasificación, que son usados también en el análisis de Potenciales Evocados.

El Capítulo 2 describe las principales herramientas y métodos utilizados en el desarrollo de esta tesis, de ahí su nombre.

El Capítulo 3 expone los resultados obtenidos a partir de la tarea desarrollada. Queda recogida la justificación de la wavelet madre que se usó en la etapa de selección de coeficientes. Las señales obtenidas por el promediado y por la reconstrucción wavelet a partir de los coeficientes seleccionados. Además de los resultados obtenidos luego de clasificar la data utilizando Redes Neuronales.

## **CAPÍTULO 1. DETECCIÓN Y RECONOCIMIENTO DE POTENCIALES EVOCADOS**

Los Potenciales Relacionados con Eventos pueden ser vistos como señales bioeléctricas especiales, las cuales están sincronizadas con cierto tipo de estímulo. En el caso de los Potenciales Evocados (PE), estos son una respuesta emitida por el cerebro ante algún tipo de estímulo, que puede ser visual, auditivo o somatosensorial. En el desarrollo de Interfaces Cerebro – Computadoras (BCI, *de sus siglas en inglés*), los PE encuentran gran utilidad, permitiendo la comunicación entre un sujeto y la computadora sin la utilización de músculos algunos y sin la necesidad de previo entrenamiento. EL siguiente capítulo hace un resumen de las características de los PE, algunas técnicas usadas para la detección de PE y para el reconocimiento de estos, que permitan su posterior uso en el desarrollo de BCI.

### **1.1. Potenciales Evocados**

Los Potenciales Evocados son señales bioeléctricas producto de la actividad que se presenta en las zonas neurales, periférica y central, como respuesta a estímulos externos. Desde otro punto de vista, son registros de la actividad eléctrica del cerebro, en respuesta a un estímulo específico que puede ser de índole auditiva, somatosensorial o visual. Estas formas de ondas consisten en una secuencia de picos y deflexiones caracterizadas por parámetros medidos sobre la señal como latencia, amplitud, polaridad eléctrica, el número de ondas en secuencia, entre otras [19-20]. Según su naturaleza los PE pueden ser clasificados en exógenos o endógenos, los exógenos son aquellas respuestas evocadas cuyos componentes electrofisiológicos se modifican fundamentalmente dependiendo de las propiedades físicas del estímulo. Suelen ser respuestas evocadas que ocurren de manera

temprana, esto es, durante los primeros 200 milisegundos(ms) después de la aplicación del estímulo, y están relacionadas principalmente con el procesamiento de estímulos sensoriales [19, 21]. Los potenciales evocados endógenos, son respuestas evocadas cuyos componentes electrofisiológicos son independientes de las propiedades físicas del estímulo, y por el contrario se modifican fundamentalmente de acuerdo con variables psicológicas como el estado de conciencia, atención, motivación, significación, etc. las cuales están relacionadas con el estado del sujeto explorado y de la tarea a realizar. Suelen ser más tardías y ocurren 200-250 milisegundos (ms) posteriores a la aplicación del estímulo, y están vinculados principalmente con el procesamiento de eventos neurocognitivo [22] [23]. Otro criterio de clasificación depende de la relación temporal con el estímulo (latencia). La latencia es un concepto temporal, e implica el intervalo de tiempo que transcurre desde el momento de la aplicación del estímulo hasta un punto específico en la morfología de la respuesta evocada. En estudios de PE, los picos en forma de onda son usados como puntos de medición y los tiempos de separación entre dos picos se denomina latencia inter-pico o latencia inter-onda. Existen diversas formas de medir la latencia; la más utilizada en los registros de PE es considerarla hasta el punto de máxima amplitud del componente evaluado, esto es lo que se conoce como latencia absoluta. Además se conoce otra forma de evaluar este parámetro: la latencia interpicos o latencia intercomponentes, que resulta de la medición de la diferencia temporal entre dos componentes relacionados [24]. Según la latencia los potenciales pueden ser de latencia corta cuando las respuestas aparecen en los primeros 10 ms después del estímulo, se encuentran también los PE de latencia media donde las respuestas aparecen entre los 10 y 50 ms posterior al estímulo, las respuestas que aparecen a partir de los 50 hasta 250 ms se consideran de latencia larga, y cuando sobrepasa los 250 ms se considera una respuesta con latencia muy larga o tardía [19, 21].

Otra forma de clasificación para los PE, es según su modalidad sensorial, estos pueden ser:

**Potenciales Evocados Auditivos:** Son las respuestas evocadas que se obtienen mediante la aplicación de un estímulo acústico o sonoro [25] [26].

**.Potenciales Evocados Visuales:** Son las respuestas que se obtienen mediante la aplicación de un estímulo visual, fótico o luminoso [27] [28].

**Potenciales Evocados Somatosensoriales:** Son las respuestas evocadas que se obtienen mediante la aplicación de estimulación eléctrica (puede incluirse el láser) a nervios periféricos o áreas dermatómicas [29-30].

**Potenciales Evocados Motores:** Son aquellas respuestas evocadas que se obtienen mediante la aplicación de estimulación eléctrica o magnética sobre vías motoras e incluso áreas de la corteza motora [31].

Atendiendo a la frecuencia de estimulación se clasifican en:

**Potenciales Evocados Transientes:** Son aquellas respuestas evocadas que se obtienen cuando ocurre un cambio o modificación en el estímulo [32].

**Potenciales Evocados Sostenidos:** Son aquellas respuestas evocadas que se obtienen sólo cuando se mantiene la continuidad del estímulo. Ambos tipos de PE se obtienen con frecuencias de estimulación suficientemente lentas como para permitir el registro de una respuesta evocada completa antes de que se presente el siguiente estímulo [33].

**Potenciales Evocados de Estado Estable:** Son aquellas respuestas evocadas que se obtienen sólo con frecuencias de estimulación tan rápidas que la respuesta transiente a un estímulo se superpone con la respuesta transiente que genera el siguiente estímulo. Esto origina un tipo de respuesta evocada periódica (casi sinusoidal) cuyos nuevos componentes electrofisiológicos (amplitud y fase) están relacionados armónicamente con la frecuencia de repetición del estímulo [19, 21].

### 1.1.1. Potenciales Evocados Visuales

Los Potenciales Evocados Visuales (PEV) son las respuestas evocadas que se obtienen ante un estímulo visual, fótico o luminoso cobrando una gran importancia en el diagnóstico actual de las afecciones de las vías visuales tanto en adulto como en niños. Inicialmente los PEV fueron estudiados con estímulos emitidos por destellos o flashes de luz que producían respuestas muchas veces inciertas e inconsistentes, lo que limitó su uso. Los PEV ganaron popularidad cuando se introdujo y difundió la estimulación por patrón reversible, mediante la presentación de modelos visuales (damero). Las respuestas generadas en la retina siguen estrechamente en su recorrido la trayectoria de las vías visuales, cualquier anomalía desde la córnea hasta la corteza occipital puede alterar los PEV. Los cuales se obtienen por

estimulación con un patrón reversible en damero (cuadrícula a manera de tablero de ajedrez) presentado en un monitor que permita modificar el tamaño de los cuadrados, los sectores de la pantalla, la velocidad de reversión de los cuadros y con la suficiente calidad para mantener un nivel constante de intensidad luminosa y de contraste. Así mismo se debe contar con un destello de luz que permita controlar la intensidad, duración y frecuencia del estímulo [34]. Generalmente los potenciales se registran en el córtex visual en el lóbulo occipital (electrodos O1, O2 y Oz) [35] en el cual los potenciales evocados visuales se hacen estacionarios (SSVEP) cuando la tasa de estimulación es superior a los 6 Hz [36]. Los pacientes cuando fijan la mirada en un objetivo parpadeante, aumentan la amplitud de la frecuencia y sus armónicos de segundo y tercer orden del SSVEP. En cuanto a la resolución de frecuencia de los SSVEP es de 0.2 Hz y el ancho de banda para su detección oscila entre 6 y 24 Hz.

### **1.1.2. Potenciales Evocados P300**

En la bibliografía se encuentran algunas descripciones de los componentes de los Potenciales Relacionados con Eventos que están asociados con diferentes fases y operaciones de la cognición humana. Estas características en la mayoría de los casos han podido ser obtenidas a través de paradigmas experimentales, de mapeos topográficos de las señales promediadas y de análisis de las fuentes eléctricas. A continuación se hace una breve descripción de estos componentes, principalmente los que son de mayor interés en el área de la neurofisiología relacionado al análisis de múltiples enfermedades neurocognitivas y cerebrales y que se pueden observar en la siguiente figura.

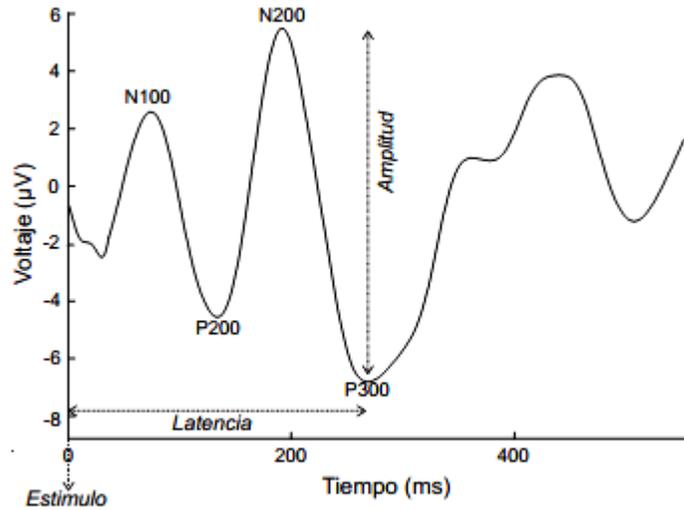


Figure 1. 1. Forma de onda de un Potencial Evocado Auditivo [5].

### P100

Alrededor de los 100 ms de ocurrido el estímulo se presenta una deflexión denominada P1. Este pico puede verse mejor definido en los electrodos del área occipital, la cual está muy próxima al área visual primaria. Por esta razón, el componente P100 representa una respuesta sensorial que se evoca por un estímulo visual sin importar la tarea que esté desarrollando el sujeto (las variaciones en las tareas pueden influir en la amplitud de P1, pero no necesariamente una tarea en particular es la que provoca dicha onda) [37] [38].

### N100

El componente N1 o N100 generalmente representa la extracción inicial de información a partir del análisis sensorial del estímulo o también puede ser interpretada como la excitación asociada a la asignación de un canal de procesamiento de la información de la corteza primaria [39], así el componente N100 muestra una amplitud mayor ante estímulos que el sujeto atiende, ya sea de forma pasiva o activa. En este intervalo de 100-200 ms es la denominada negatividad del procesamiento que puede solaparse con N100 [40-41].

### P200

Otro componente positivo es el denominado pico P200 o P2, que puede distinguirse en las ubicaciones central y anterior del cuero cabelludo. Este componente presenta mayor amplitud ante estímulos que contiene características denominadas diana (*target* en inglés),

y su efecto aumenta cuando los *targets* son relativamente infrecuentes. En este sentido, la P200 de la zona anterior es similar a la onda P300. Sin embargo, la P2 anterior sólo ocurre cuando el *target* está definido por estímulos de características muy simples, mientras que los efectos de la P300 pueden ocurrir por categorías de *targets* complejos que aparecen arbitrariamente [42-43]

### **N200**

La N200 o N2 es una negatividad resultante de una desviación en forma de un estímulo predominante, típicamente evocado entre los 180 y 325 ms después de la presentación de un estímulo auditivo o visual. La generación de esta respuesta puede ser alcanzada mediante el paradigma experimental *oddball*, en el cual los sujetos son expuestos a una sucesión continua de dos tipos de estímulos, uno que se presenta regularmente y otro que se manifiesta esporádicamente [44].

### **P300**

El potencial evocado P300 se utiliza en muchos sistemas BCI porque es una respuesta típica e ingenua a una opción deseada. Una ventaja importante de un BCI basado en P300 es que no requiere la formación previa de ningún usuario [45]. Sin embargo, el P300 puede estar influenciado por diversos factores humanos, tales como la atención, la motivación y la fatiga. La medida en que esos factores afectan el funcionamiento BCI aún no se ha explorado [23, 46].

La onda P300 ha sido objeto de numerosos estudios relativos a los procesos cognitivos, procesamiento de la información y la atención selectiva [39], debido en parte a su amplitud relativamente grande y fácil obtención en contextos experimentales. Este componente, de polaridad “positiva” y latencia promedio de 300 ms, es evocado principalmente en tareas discriminativas con estimulación auditiva, visual o somatosensorial (paradigma *oddball*), mediante la aparición inesperada de un estímulo infrecuente (también llamados estímulos dianas o raros) [19]. La onda P300 depende enteramente de las tareas ejecutadas por el sujeto y no está directamente influenciada por propiedades físicas de la generación del estímulo. La P300 es por tanto, un componente tipo endógeno debido a su dependencia a factores internos y no externos [42]. En varias patologías relacionadas a la cognición, la onda P300 muestra alguna alteración que refleja anormalidad de la respuesta, tal como

sucede en la depresión, la esquizofrenia, la demencia, entre otras [47-48]. Se desconocen las estructuras anatómicas responsables de la distribución topográfica de la P300. El hipocampo y áreas adyacentes del sistema límbico se activan al mismo tiempo que se registra el P300; sin embargo, una lobectomía temporal unilateral no afecta la distribución topográfica de la P300. Es posible entonces que la P300 represente actividad generada tanto en sistema límbico como en áreas asociativas parietales. Aunque los orígenes neurales de la P300 continúan en debate, los registros con electrodos profundos en humanos indican que al menos alguna porción de la P300 se genera muy probablemente en el lóbulo temporal medio. La amplitud varía en función de las características como la facilidad de discriminar entre estímulos estándar y objetivo, volumen de tonos en caso de estímulos auditivos, probabilidad del estímulo objetivo, secuencia del estímulo y por último la colocación de los electrodos [49].

#### **N400**

Este componente ha despertado un especial interés en diferentes áreas de investigación debido a los signos de procesamiento del lenguaje que muestra. En [50], Kutas y Hillyard describen una deflexión negativa que se presenta entre los 300 y los 500 ms después de la estimulación (haciendo referencia a la N400), la cual está correlacionada con la aparición de palabras semánticamente anómalas en oraciones con sentido contrario. Lo anterior refleja la memoria semántica, es decir, la previsibilidad de una palabra basada en el contenido semántico de la oración anterior [4] [37].

#### **1.2. Promediado Coherente**

El Promediado Coherente consiste en hacer la promediación de las respuestas individuales obtenidas en la repetición de un mismo experimento; de esta manera, el ruido esporádico conformado por el EEG, el EMG, y la interferencia eléctrica, es reducido substancialmente y los PE se manifiestan de forma más clara. Esta técnica se realiza bajo la presunción que el PE es invariante en el tiempo, ya que el EEG tiene por lo menos una distribución estadística simétrica. Además, para que esta técnica resulte confiable, debe asumirse que cada vez que un estímulo dado se presente, provocará esencialmente el mismo potencial evocado; de esta manera, la amplitud y polaridad que exhiben los PE serán razonablemente estables (en tiempos fijos) en relación con el estímulo y no se cancelarán al promediar el número de

repeticiones, lo cual si ocurriría con el ruido de fondo al presentar amplitudes y polaridades eventuales en cualquier instante que sigue al estímulo. Según la ecuación 1.1, la respuesta puede ser obtenida realizando el promedio de las respuestas a cada uno de los estímulos, donde  $N$  es el número total de estímulos,  $x_i$  es la respuesta  $i$ -ésima al estímulo  $i$ -ésimo [51] [52].

$$M_{mean} = \sum_{i=1}^N \frac{1}{N} x_i \quad (1.1)$$

Los estándares para la obtención de PEV [53] sugieren estimular de 100 a 200 veces con el fin de obtener una respuesta confiable y 400 veces, para garantizar reproducibilidad. Otros potenciales evocados requieren de un número mayor de respuestas a promediar, dado que poseen valores de amplitud mucho menores que los de los PEA [54]. Si bien la promediación coherente es ampliamente aceptada, presenta ciertas limitaciones. La más importante es que supone que la señal de potencial evocado se repite exactamente igual en cada época, lo cual no es cierto en la mayoría de los casos. Otra limitación a considerar es el tiempo necesario para obtener una estimación de la señal. Por ejemplo, en la literatura se plantea [55] la relación señal a ruido (SNR, de sus siglas en inglés) mejora por un factor de  $\sqrt{K}$ , donde  $K$  es el número total de épocas a promediar. Para el caso de los PEV, estos tienen mayor amplitud, generalmente alrededor de 20  $\mu\text{V}$ , y la señal EEG, considerada la principal fuente de ruido, tiene una amplitud de aproximadamente 50  $\mu\text{V}$ , la SNR inicial es de  $-8$  dB aproximadamente. Para alcanzar una SNR mínima de 6 dB, el mínimo valor permisible [53], se requiere promediar alrededor  $K = 196$  épocas para que ocurra tal mejora. En el caso que se quiera obtener registros de potenciales cognitivos, caracterizados por la onda P300, el hecho de promediar respuestas obtenidas cada 450 ms mínimo, que realmente es necesario más tiempo, el proceso se tardaría alrededor de 88,2 s y dado que se deben obtener dos registros para verificar la reproducibilidad [55], aproximadamente el mínimo tiempo requerido debe ser de 2,94 min. Esto justifica el hecho de la necesidad de aplicar otras técnicas que disminuyan el tiempo de obtención de un PE.

### 1.3. Características basadas en transformada wavelet

En la literatura se proponen diversas alternativas para la obtención de un PE con el fin de contrarrestar las limitaciones del Promediado Coherente, y que facilitan el uso de estos en el desarrollo de BCI, una de ellas es la Transformada Wavelet.

#### 1.3.1. Transformada Wavelet (TW)

Una señal puede ser considerada como estacionaria si sus características estadísticas no cambian con el tiempo. Las señales estacionarias pueden ser analizadas usando métodos clásicos como la transformada de Fourier (FT, de sus siglas en inglés), en los cuales la señal se puede expandir en las funciones de base ortogonal (ondas seno y coseno). Esto permite una mejor visualización de las periodicidades de la señal, especialmente cuando varias frecuencias están superpuestas; sin embargo, la FT no da información sobre la localización temporal de tales periodicidades, lo cual supone la asunción de estacionareidad de la señal. La mayoría de señales biomédicas son no estacionarias y tienen características tiempo-frecuencia altamente complejas. El método de Transformada de Fourier de Tiempo Corto (STFT) en la cual la condición de estacionareidad para las señales no estacionarias puede ser alcanzada dividiendo la señal en bloques de segmentos cortos en los que el segmento de la señal puede ser asumido como estacionario. La STFT da una óptima representación tiempo-frecuencia, pero presenta una limitación debido al principio de incertidumbre: la longitud del segmento deseado. Elegir una ventana de análisis pequeña puede causar una pobre resolución en la frecuencia; por otra parte, una ventana de análisis grande puede mejorar la resolución en frecuencia pero compromete la suposición de estacionareidad dentro de la ventana [4]. Por tal motivo, la STFT no es aconsejable para el análisis de señales que involucren diferentes rangos de frecuencias, como es el caso de los PE [56]. En 1984, Grossmann y Morlet [57] introducen la transformada wavelet para superar esta restricción. La principal ventaja de las wavelet es su variabilidad en el tamaño de las ventanas deslizantes, siendo anchas para las frecuencias bajas y angostas para las altas; de esta manera se lleva a una óptima resolución tiempo-frecuencia en todos los rangos de frecuencia. Dado que las ventanas se adaptan a los transitorios de cada escala, las wavelet no requieren la condición de estacionareidad. Además es una útil herramienta de uso común en el análisis de potenciales relacionados

con eventos (PRE). Mediante la representación tiempo-frecuencia, los finos detalles de la estructura de los PE pueden ser examinados a una mayor escala; en particular, permite una resolución en tiempo teóricamente ilimitada para la detección de picos de corta duración, y admite una flexible selección de funciones bases wavelet para el análisis de diferentes tipos de PE. Entre las aplicaciones más comunes del análisis wavelet en los PE se encuentran:

- la ubicación precisa en el tiempo de la ocurrencia de solapamiento entre picos en respuestas evocadas auditivas de tallo cerebral;
- la extracción de registros PE individuales (sin promediar) a partir del ruido de fondo del EEG;
- la descomposición del PE promediado en funciones de detalle ortogonal que desliga el comportamiento experimental de la forma de onda en bandas de frecuencia ortogonales;
- el uso de los coeficientes wavelet extrae de forma concisa información importante de los PE que permiten predecir el rendimiento de la detección de las señales humanas [3, 5].

Para la eliminación del ruido EEG el método tradicional de promediación de los registros individuales para la extracción de los potenciales da estructura a una forma de onda, este procedimiento presume la pérdida de información que podría representar componentes adicionales en el registro de la señal. Por tal motivo, en la última década muchos investigadores se han enfocado en la búsqueda de otras alternativas que permitan la eliminación de ruido EEG con la menor pérdida de información posible. Partiendo desde este punto de vista, en la definición convencional de eliminación de ruido implica un criterio de umbralización en el dominio wavelet. La señal se recupera de los datos con ruido poniendo en cero los coeficientes wavelet que están por debajo de cierto umbral o con el uso de una transformación más suave. Sin embargo, este procedimiento no es óptimo para extraer los PE dado que éstos son de un orden mucho menor que el EEG en curso. Para contrarrestar esta limitación, en trabajos posteriores se ha planteado la eliminación de ruido basado en la localización específica en tiempo y en frecuencia de las respuestas evocadas. En este orden de ideas, en [56] se propone una metodología basada en un esquema de descomposición wavelet, a fin de obtener las señales de PE a partir de la señal

EEG en curso. El método permite la visualización de un único registro de potenciales evocados, haciendo énfasis en la variabilidad de su amplitud y latencia entre una prueba y otra. Básicamente, el procedimiento propuesto consiste, en primera instancia, en descomponer el PE promediado (en la literatura conocida como *grand average*) usando una descomposición wavelet multiresolución, y aquellos coeficientes no correlacionados con tal registro promedio son puestos en cero. Posteriormente se aplica la transformada wavelet inversa para obtener la señal sin ruido. Dado que el método mostrado es no-paramétrico y no debe ser adaptado a características particulares de cada registro, puede ser de gran utilidad en la práctica clínica. En busca de este objetivo, la TW ha sido aplicada en la distinción de respuesta a estímulos *target* y a estímulos frecuentes. Para la detección de componentes de los PE se presenta una aplicación del filtrado wavelet para el análisis del componente P300 en registros individuales dado una tarea cognitiva. Para lograr tal objetivo se emplea la Transformada Wavelet Discreta [58].

### 1.3.2. Transformada wavelet discreta (DWT)

La Transformada wavelet continua (CWT) mapea la señal de una variable independiente  $t$  a una función de dos variables ( $a, b$ ). Este procedimiento es redundante y poco eficiente a la hora de implementar algoritmos. En consecuencia es más práctico definir la transformada wavelet solo en escalas discretas  $a$  y tiempos discretos  $b$ . En este caso la transformada viene dada por la ecuación 1.4:

$$CWT(2^i, b) = |2^i|^{-\frac{1}{2}} \int_{-\infty}^{\infty} x(t) \psi * \left(\frac{t-b}{2^i}\right) \quad (1.2)$$

Cada  $i$  se le denomina octava o escala, y consiste en cada uno de los niveles en los que se descompone la señal. Las escalas bajas tienen en cuenta las bajas frecuencias, y las frecuencias mayores son tenidas en cuenta por las escalas altas. Se usan wavelet ortonormales (desde el punto de vista de funciones de cuadrado integrable  $L^2$ ), lo habitual es usar el procedimiento de diezmado. Consiste en descomponer la señal en un número de coeficientes proporcional a la escala analizada. Esto hace que la señal tenga distintos números de coeficientes en cada escala reflejando físicamente el hecho de que las frecuencias menores de una señal necesitan menos coeficientes para ser representados [59]. Una transformada de wavelet diezmada es:

$$CWT(2^i, 2^i \cdot n) = |2^i|^{-\frac{1}{2}} \int_{-\infty}^{\infty} x(t) \psi * \left(\frac{t-b}{2^i}\right) \quad (1.3)$$

A partir de esta ecuación es posible definir la versión discretizada de la transformada wavelet como sigue:

$$DWT(2^i, 2^i \cdot n) = |2^i|^{-\frac{1}{2}} \sum_k x(k) \psi^* \left(\frac{k}{2^i} - n\right) \quad (1.4)$$

### 1.3.3. Análisis multiresolución

El análisis multiresolución (MRA, de sus siglas en inglés) es una herramienta que hace uso de la DWT para representar una señal de tiempo variante en términos de sus componentes de frecuencias. Este método consiste en mapear una señal unidimensional del tiempo a una señal bidimensional de tiempo y frecuencia. La función del MRA es aproximar una señal  $s(n)$  con un límite de aproximaciones sucesivas; las diferencias entre las aproximaciones sucesivas entre la resolución  $2^{j-1}$  y  $2$  dan los detalles de la señal  $2^j$ . Lo anterior se refiere a que, después de elegir una resolución inicial  $J$  cualquier señal  $s(n) \in L^2(\mathbb{R})$  puede ser expresada como [60]:

$$s(n) = \sum_{k \in \mathbb{Z}} c_{j,k} \varphi_{j,k}(n) + \sum_{j=J}^{\infty} \sum_{k \in \mathbb{Z}} d_{j,k} w_{j,k}(n) \quad (1.5)$$

donde los detalles o coeficientes de wavelets  $\{d_{j,k}\}$  se expresa de la siguiente manera:

$$d_{j,k} = 2^{-1/2} \int_{-\infty}^{\infty} s(n) w_{j,k}(2^{-j}n - k) dn \quad (1.6)$$

las aproximaciones o coeficientes de escala  $\{c_{j,k}\}$  se expresa de la siguiente manera:

$$c_{j,k} = 2^{-1/2} \int_{-\infty}^{\infty} s(n) \psi_{j,k}(2^{-j}n - k) dn \quad (1.7)$$

De esta manera se lleva a cabo el MRA de la señal  $s(n)$  expresada en términos de sus coeficientes de detalles y los coeficientes de aproximación.

### 1.4. Diferenciación de respuesta a estímulos *target* y *no-target*

Los potenciales relacionados a eventos son especialmente utilizados en el desarrollo de BCI, el cual consiste en un sistema de comunicación que traduce la actividad cerebral en comandos para una computadora u otros dispositivos. En busca de este objetivo, la TW ha sido aplicada en la distinción de respuesta a estímulos *target* y a estímulos frecuentes. En

[61] se usa como wavelet madre la función B-spline para descomponer los PRE en cuatro octavas. El análisis realizado indica que varios componentes de las frecuencias delta (0,2 a 3,5 Hz), theta (3,5 a 7,5 Hz) y alfa (7,5 a 13 Hz) en el rango de latencia del pico P300 difieren en latencia y amplitud entre las respuestas *target* y las *no-target*. Este hallazgo demuestra que la onda P300 está compuesta de múltiples componentes funcionales que predominan ante un estímulo infrecuente [5].

### 1.5. Técnicas de clasificación para BCI basadas en el uso del deletreador con P300

En la literatura se proponen un grupo de distintas técnicas y procedimientos [62] que han sido implementadas con el fin de clasificar las respuestas, e incluso de mejorar esta clasificación. Varias técnicas como: análisis discriminante lineal (discriminante lineal de Fisher), máquinas de soporte vectorial, método de correlación de Pearson, entre otras han sido propuestas [62]. A continuación se describen someramente estas técnicas.

#### 1.5.1. Método de correlación Pearson

El coeficiente de correlación de Pearson es una herramienta de análisis estadístico que puede ser usado para test de significancia de predictores variables. El índice de Pearson mide el grado de correlación entre dos series  $X = (x_i, 1 \leq i \leq L)$  y  $Y = (y_i, 1 \leq i \leq L)$ , relacionadas linealmente y está definido por:

$$r = \frac{L \sum x_i y_i - \sum x_i \sum y_i}{\sqrt{(L \sum x_i^2 - (\sum x_i)^2)(L \sum y_i^2 - (\sum y_i)^2)}} \quad (1.8)$$

Donde  $L$  es el número de respuestas en el set de entrenamiento,  $y_i$  son las etiquetas de las clases correspondientes a cada estímulo y  $x_i$  son los valores de las características de entrada de cada estímulo. Si las series son proporcionales  $r$  será igual a  $\pm 1$ , si las series no muestran correlación  $r$  será igual a cero. Valores absolutos altos de  $r$  indican mayor significancia del predictor en el modelo [62].

#### 1.5.2. Discriminante Linear de Fisher

El discriminante lineal de Fisher (FLD) es un clasificador simple que proporciona una precisión bastante buena sin requisitos computacionales. Es un método bastante común en las BCI ya que permite su diseño con el objetivo de obtener respuestas rápidas con recursos computacionales limitados. Este método es un punto de referencia para determinar

óptimamente la separación de dos clases en hiperplanos. FLD es simple y provee de un método robusto de clasificación cuando dos clases tienen distribución gaussiana con igual covarianza. Para tareas de clasificación binaria FLD es equivalente a solucionar el problema usando Regresión de Mínimos Cuadrados (*least-squares regression*), los valores de los pesos característicos se calcula a partir de la siguiente ecuación:

$$\hat{w} = (X^T X)^{-1} X^T y \quad (1.9)$$

donde  $X$  es la matriz de vectores de características y  $y$  es el vector de clases [62].

### 1.6. Redes Neuronales

Una red neuronal es un modelo computacional que pretende simular el funcionamiento del cerebro a partir del desarrollo de una arquitectura que toma rasgos del funcionamiento de este órgano sin llegar a desarrollar una réplica del mismo.

El uso de redes neuronales (RN) para sistemas de control y procesamiento de señales ha sido gratamente aceptado por la comunidad científica. La mayoría de sus aplicaciones se reportan en el campo de las telecomunicaciones, reconocimiento de patrones, análisis financiero y de predicciones, control de procesos, reconocimiento del lenguaje y bioinformática [63]. Las redes neuronales artificiales (RNA) pueden definirse como un sistema de procesamiento de información compuesto por un gran número de elementos de procesamiento (neuronas) conectadas entre sí a través de canales de comunicación. La Figure 1. 2 muestra el esquema de una neurona simple. Una neurona consta de un nivel de activación  $\tau$  (*bias*), un conjunto de conexiones de entrada  $(x_1, \dots, x_n)$ , con un peso asociado a cada una de ellas  $(w_1, \dots, w_n)$ , y una salida ( $y$ ). La salida de una neurona es determinada como:

$$y = f[\sum_i^n w_i x_i + \tau] \quad (1.10)$$

donde  $(x_1, \dots, x_n)$ , son las señales de entrada,  $(w_1, \dots, w_n)$  son los pesos de las conexiones de entrada,  $\tau$  es el valor del *bias* y  $f$  es una función de salida definida, que puede ser una tangente hiperbólica, paso unitario, etc.

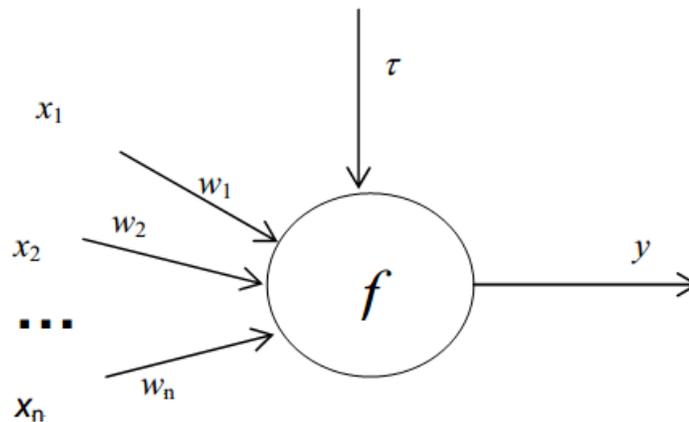


Figure 1. 2. Esquema de una neurona simple

Estas conexiones establecen una estructura jerárquica y permite la interacción con los objetos del mundo real tratando de emular al sistema nervioso biológico. A diferencia de la computación tradicional basada en algoritmos predecibles, la computación neuronal permite desarrollar sistema que resuelven problemas complejos cuya formalización matemática es compleja. El principio de funcionamiento se basa en cinco aspectos fundamentales como son [64]:

**Aprendizaje adaptativo:** es la característica más importante de las RNA ya que puede comportarse atendiendo a un entrenamiento con un número de ejemplos ilustrados permitiendo que no sea necesario elaborar un modelo a priori, ni establecer funciones probabilística. Una RNA es adaptativa ya que presenta la capacidad de poder modificarse constantemente con el objetivo de adaptarse a nuevas condiciones de trabajo.

**Autoorganización:** permite la modificación de toda la red con el objetivo de llevar a cabo un objetivo específico, de esta forma la red puede responder a datos o situaciones que no ha experimentado antes.

**Tolerancia a fallos:** presenta una alta tolerancia a fallos relacionado con la pérdida de la información ya que permite el reconocimiento de patrones de información con ruido, distorsión o incompletos; y segundo, puede seguir trabajando aunque se destruya parte de la red.

**Operación en tiempo real:** las RNA son las más indicadas para el reconocimiento de patrones en tiempo real debido a que trabaja en paralelo actualizando todas sus instancias simultáneamente.

**Fácil inserción en la tecnología existente:** Con las herramientas computacionales existentes una red puede ser rápidamente entrenada, comprobada, verificada y trasladada a una implementación de hardware de bajo costo para la realización de determinada tarea.

La RNA está constituida por neuronas artificiales que tienen entradas y salidas, pesos sinápticos, regla de propagación, función de activación y función de salida. Las cuales se unen según cierta arquitectura formando capas y el conjunto de capas forman la red neuronal. Se considera que una red neuronal tiene una capa de entrada y una capa de salida dependiendo del uso que se le quiera dar a la red neuronal, si tendrá una o más capas ocultas (intermedias). Cada capa de neurona tiene su respectiva función de activación y de salida, que permite transformar una entrada en una salida. El paso de datos para probar si la red permite obtener el resultado esperado se conoce como época, por lo general para resolver un problema una red realiza más de 1000 épocas (cálculos); no siempre llega a la solución por lo cual se recomienda probar otro algoritmo de los que se reportan en la literatura (alrededor de 20 hasta la actualidad). Una vez que se ha alcanzado llegar a la salida buscada, termina la etapa de aprendizaje de la red, posteriormente se puede pasar a la red una entrada cualquiera y comprobar su funcionamiento. Es decir se tienen dos etapas distintas: una de entrenamiento de la red (búsqueda de la salida esperada) y la otra de aplicación de la red entrenada a cualquier entrada.

Según el tipo de arquitectura y funciones que se utilicen se tienen diversos modelos de RNA. Los modelos más conocidos se clasifican en supervisados y no supervisados. Dentro de los primeros se tienen los modelos más simples y los que más se utilizan: Perceptron, Backpropagation BP, Adalina, LVQ, GRNN, Perceptron Multicapa, Madalina. Dentro de los no supervisados son usados el de Realimentación de Hopfield y el Unidireccional de Mapas de Kohonen [65].

### **1.6.1 Reconocimiento de RN utilizando propagación para atrás**

Las Redes Neuronales con algoritmo de entrenamiento *Backpropagation* han sido usadas en el reconocimiento de Potenciales Evocados para producir la señal de control de los BCI

[3]. Actualmente existen compañías como *NeuroSky*, (compañía con sede en San José, California) que han logrado poner en práctica ciertos tipos de audífonos habilitados con comunicación *Bluetooth* que pueden monitorear mínimos cambios en las ondas cerebrales, permitiendo a las personas jugar juegos de concentración en computadoras y teléfonos móviles [66]. El método de Backpropagation (BP) es un sistema automático de entrenamiento de redes neuronales con capas ocultas. En este tipo de redes, el problema a la hora de entrenarlas es que solo conocemos la entrada y la salida de la red, de forma que no se pueden ajustar los pesos sinápticos asociados a las neuronas de las capas ocultas, ya que no podemos inferir a partir del estado de la capa de salida como tiene que ser el estado de las capas ocultas. Básicamente el proceso BP consiste en dos pasadas a través de las diferentes capas de la red, una pasada hacia adelante y una pasada hacia atrás. En la pasada hacia adelante, se aplica en la capa de entrada un patrón o vector de entrada, este propaga su efecto a través de las diferentes capas y como consecuencia produce un vector de salida. Durante este proceso, los pesos sinápticos de la red son fijos y no se modifican. Durante la pasada hacia atrás en cambio, los pesos si se modifican de acuerdo con la regla de corrección del error. La señal de salida real se compara con la señal deseada y como resultado se obtiene una señal de error, que se propaga en dirección contraria a través de la red modificando los pesos, de forma que, al volver a pasar el vector de entrada hacia adelante, la respuesta obtenida se asemeje más a la salida deseada.

### **1.7. Conclusiones del Capítulo**

En este capítulo se describieron algunas características principales de los Potenciales Evocados, principalmente de los visuales y de los cognitivos. Se realizó un estudio de la transformada wavelet discreta, partiendo del hecho de que está permite realizar un análisis multiresolución de la señal en cuestión, que permite extraer coeficientes como rasgos que pueden servir para caracterizar una señal. Se mencionaron algunos métodos descritos en la bibliografía para la clasificación de respuestas en diferentes clases. En el próximo capítulo se describirán las herramientas utilizadas en este proyecto.

## CAPÍTULO 2. MATERIALES Y MÉTODOS

En este capítulo se explicará todos los materiales y métodos utilizados para lograr la extracción de los coeficientes correspondientes al Potencial Evocado P300 utilizando transformada wavelet discreta y su clasificación utilizando Redes Neuronales.

### 2.1 Características de la base de datos

Para la realización de este Trabajo se utilizó la base de datos ofrecida en *Physionet, ERP-based Brain-Computer Interface recordings*. Para la confección de esta base de datos participaron 12 sujetos. Los sujetos fueron sentados confortablemente frente a una pantalla de 22" LCD, a una distancia de 80 cm. Los datos fueron obtenidos utilizando 64 electrodos, posicionados sobre el cuero cabelludo cumpliendo con la norma internacional 10/20. Los datos fueron grabados utilizando el sistema *BioSemi Active Two EEG*. La Tabla 2. 1 recoge algunas de las características de este equipo.

Tabla 2. 1. Especificaciones del equipo *BioSemi Active Two EEG*

<b>Frecuencia de muestreo ajustable</b>	2048 Hz	4096 Hz	8192 Hz	16,384 Hz
<b>Ancho de banda</b>	DC - 400 Hz	DC - 800 Hz	DC - 1600 Hz	DC - 3200 Hz
<b>DC offset:</b>	< 0.5 mV			
<b>Rango de entrada</b>	+/-260mV or +/- 1Volt			
<b>Razón de Rechazo al Modo Común</b>	> 100 dB @ 50 Hz			

<b>Interfaz con PC</b>	USB2.0
<b>Convertidor Análogo digital</b>	Sigma Delta

Los datos fueron obtenidos utilizando una frecuencia de muestreo igual a 2048 Hz. A cada participante se le preguntaron un total de 20 caracteres. Los caracteres diana (*target*) fueron escogidos aleatoriamente antes del comienzo de cada sesión. El registro de las señales se realizó a partir de la utilización de un deletreador Donchin. Un deletreador Donchin consiste en una matriz de 6 X 6, tal como se muestra en la Figura 2. 1. Cada fila y columna es intensificada aleatoriamente durante 100 ms con un intervalo de 50 ms entre intensificaciones, produciéndose un estímulo asincrónico de 150 ms. Durante una corrida cada fila y columna es intensificada 20 veces. A los sujetos se le pide que se centren en el carácter objetivo y que traten de contar mentalmente las veces que este es intensificado.

A	B	C	D	E	F
G	H	I	J	K	L
M	N	O	P	Q	R
S	T	U	V	W	X
Y	Z	1	2	3	4
5	6	7	8	9	_

Figura 2. 1. Deletreador Donchin.

En la base de datos ofrecida se ofrecen los conjuntos de datos correspondientes a cada electrodo, los factores desencadenantes y las anotaciones correspondientes, brindando la información necesaria que permite la reutilización de esta base de datos en otras pruebas. Vale aclarar que el uso primario de esta base de datos fue para determinar los cambios de la amplitud del P300 teniendo en cuenta los estímulos *no target* que anteceden a la presencia de un flash que contiene un *target*.

## 2.2 Organización de la Data

Con el propósito de reutilizar la data y llevar a cabo el experimento que se desarrolla en esta tesis se reorganizaron los datos. La organización de los datos se hizo dividiendo la data en respuestas que corresponden a caracteres *target* y *no target*.

Los datos utilizados corresponden a los registros obtenidos a partir del electrodo posicionado en Oz. La selección de este electrodo se realizó teniendo en cuenta que las respuestas evocadas visuales de mayor amplitud se obtienen en la región occipital. Los datos son convertidos a unidades de ingeniería a partir de la información reportada en los ficheros dados en *Physionet*, de la siguiente manera:

$$x[\mu V] = \frac{(x[u]-b)}{g}, \quad (2.1)$$

donde:

$x[\mu V]$  es la señal en  $\mu V$ , llevada ya a unidades de ingeniería

$x[u]$  los datos obtenidos por el convertidor

$b$  es la base del sistema, en este caso es cero.

$g$  es la ganancia del sistema, en este caso es igual a 31.9995742179

Un registro debe tener una duración de 36 s, el equivalente de intensificar 20 veces cada fila y columna,  $20*12*150 \text{ ms} = 36 \text{ s}$ . La figura Figura 2. 2 muestra el registro completo de un sujeto, 33 s de señal aproximadamente.

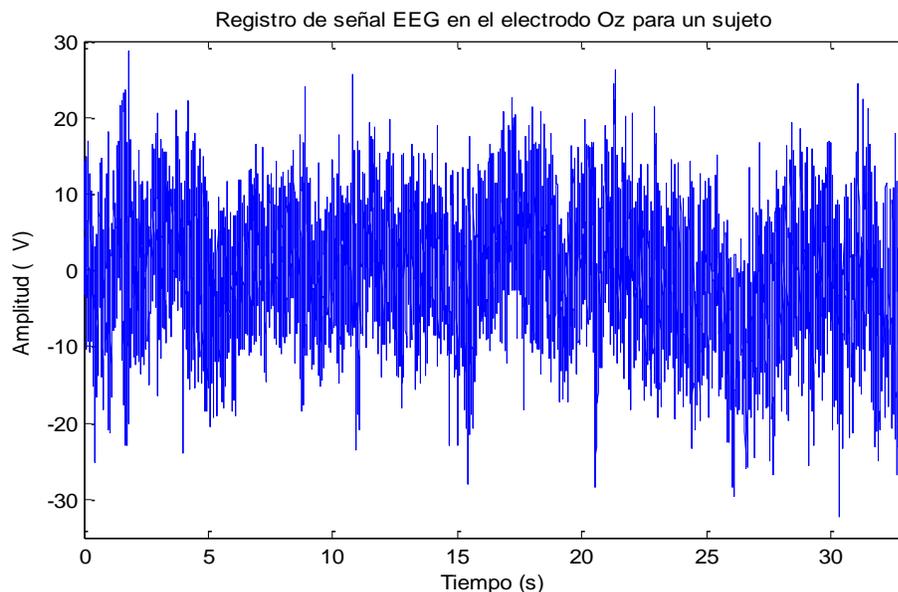


Figura 2. 2. Registro crudo perteneciente a un sujeto, señal EEG más PE.

La data es segmentada con el fin de obtener una matriz que contenga las respuestas a los caracteres *target* y una que contenga las respuestas a los caracteres no *target*. Para la

segmentación es importante tener en cuenta que cada fila y columna es intensificada cada 150 ms, mientras que la presencia de un potencial P300, como su nombre lo indica ocurre transcurridos 300 ms de haberse efectuado el estímulo sobre el carácter seleccionado como diana. A partir de las anotaciones correspondientes dadas en Physionet, donde se sabe de antemano en que muestra exactamente se produce el estímulo de cada fila y columna, se identificaron las posiciones de los *target* y se segmentó la señal en tramos de 500 ms, 50 ms antes del *target* y 450 ms después con el propósito de obtener el potencial cognitivo completo. Para evitar los solapamientos en las respuestas se descartaron aquellos *target* que aparecían consecutivamente, en el intervalo descrito anteriormente, de igual manera se escogieron segmentos de señal correspondientes a respuestas a no *target*, tratando de igual manera evitar el solapamiento. Las figuras 2.3 y 2.4 muestran la conformación de las matrices correspondientes a las respuestas de los *target* y de los no *target*.

Conformación de la matriz de respuestas a caracteres dianas

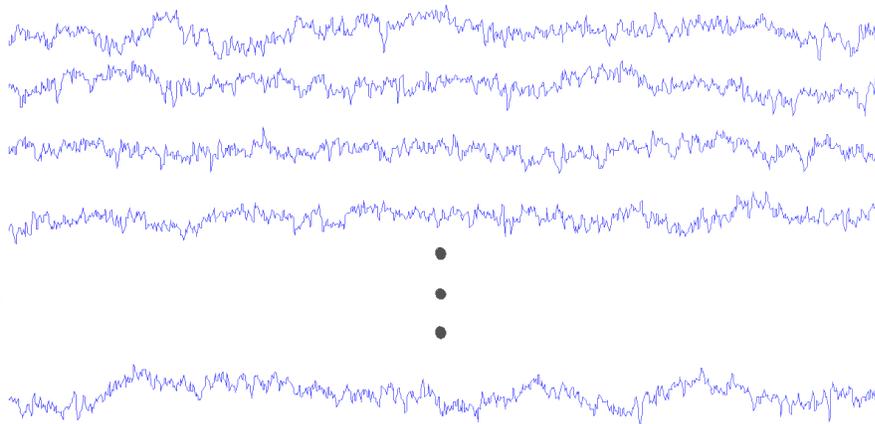


Figura 2. 3. Conformación de una matriz de segmentos de señal correspondiente a respuestas a caracteres dianas.

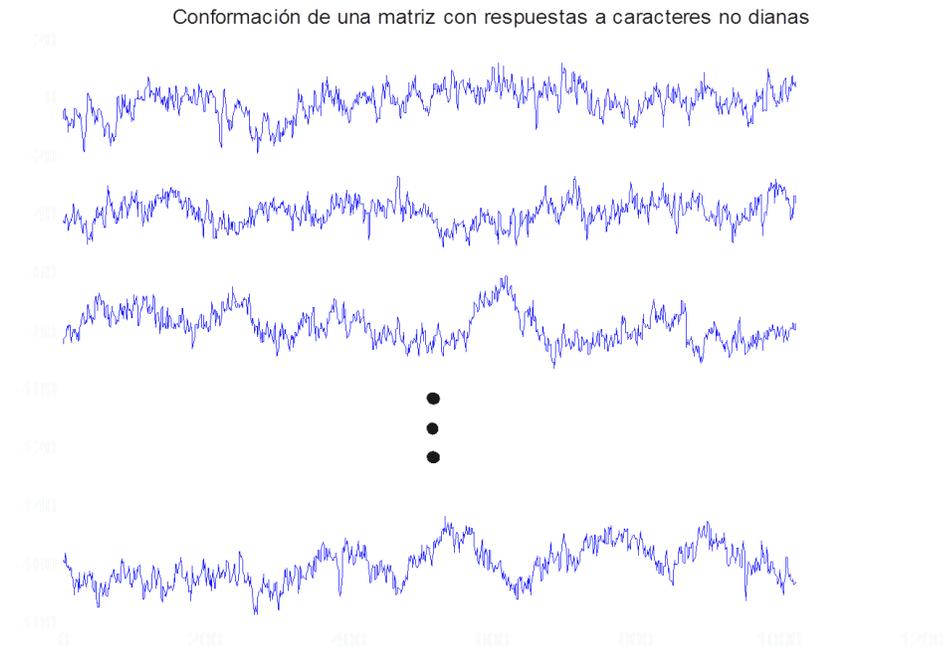


Figura 2. 4. Conformación de una matriz de segmentos de señal correspondiente a respuestas a caracteres no dianas.

La organización de los datos se obtuvo para un total de 27 registros, obteniendo 27 matrices correspondientes a *target* y 27 matrices correspondientes a no *target*, 3 registros para los pacientes 1, 2 y 3 pacientes correspondientes a 3 caracteres diferentes y 2 registros para el resto de los pacientes.

### 2.3 Preprocesamiento de los datos

El método de promediado es la técnica tradicional para mejorar la relación señal a ruido (SNR) y obtener los potenciales evocados. El promediado coherente es el mejor estimador no sesgado cuando el número de muestras tiende a infinito. En este caso se cuenta con un número relativamente bajo de respuestas a promediar, por lo que las señales obtenidas a partir del promediado no son concluyentes. Para el caso particular de sistemas BCI, donde la velocidad de la comunicación tiene un gran impacto se sugiere usar otras técnicas que aminoren el retardo en la obtención de un potencial evocado fiable. Las matrices obtenidas en el subepígrafe anterior son promediadas, obteniendo una estimación del Potencial Evocado.

Las señales obtenidas con el promediado son normalizadas con el fin de estandarizar los valores de la señal, eliminar componentes AC, a fin de garantizar coherencia en las fluctuaciones de las señales de la base de datos y permitir la reconstrucción de la señal descompuesta utilizando wavelet. Para tal efecto se aplica la siguiente fórmula.

$$x_i = \frac{x_i - \bar{x}}{\sigma x}, \quad (2.2)$$

donde:

$x_i$  es el elemento  $i$ -ésimo de la señal

$\bar{x}$  es la media de la señal

$\sigma x$  es la desviación estándar de la señal.

Las señales normalizadas son remuestreadas por un factor de 8, con el fin de aplicar transformada wavelet discreta.

#### 2.4 Transformada Wavelet y selección de coeficientes

La transformada wavelet ha sido extensamente utilizada en el análisis del PRE por su habilidad de explorar efectivamente tanto las características del PRE en el dominio del tiempo como en el de la frecuencia ([67]). Las señales fueron remuestreadas a 256 Hz y descompuestas en 6 niveles de descomposición, con el fin de ajustar de forma aproximada las bandas de frecuencia de los niveles a los ritmos cerebrales *delta* (0,2 a 3,5 Hz), *theta* (3,5 a 7,5 Hz), *alfa* (7,5 a 13 Hz) y *beta* (13 a 28 Hz). Como se mencionó en capítulo anterior se reportan algunas referencias que muestran que los ritmos *delta*, *theta* y *alfa* en el rango de latencia del pico P300 difieren en latencia y amplitud entre las respuestas *target* y *no target*. Por lo que el estudio de los rangos de estos segmentos puede ser considerado para diferenciar entre estas señales. La descomposición wavelet de las señales queda como se muestra en la Figura 2. 5. Los coeficientes que interesan son los correspondientes a A6, D6, D5 y D4. El resto de los coeficientes son puestos a cero en el momento de realizar la reconstrucción de la señal.

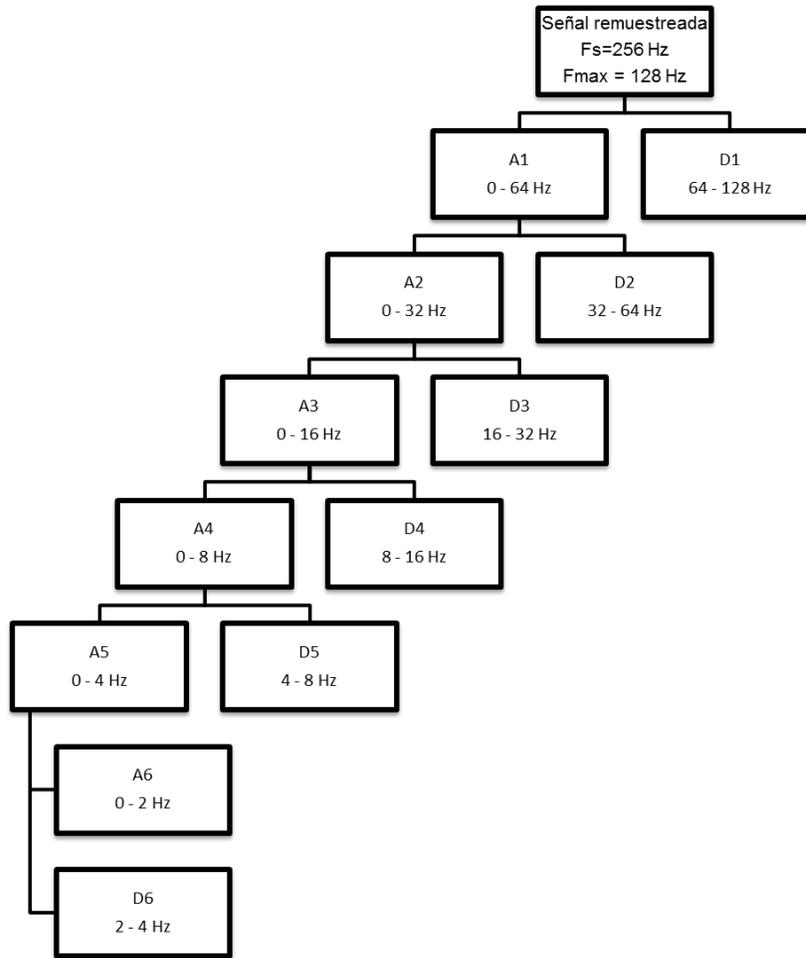


Figura 2. 5. Descomposición wavelet de las señales

### Selección de la wavelet madre a usar

Para realizar la descomposición de las señales se utilizó la wavelet madre *coif4*, (ver Figura 2. 6). La selección de la función *coif4* se realizó partiendo de los resultados obtenidos al calcular el valor *RMS* de la señal reconstruida a partir de los coeficientes seleccionados para cuatro tipos diferentes de wavelet madres, *coif4*, *db6*, *rbio1.5* y *haar*. La elección de las tres primeras wavelet se realizó a partir de lo reportado en algunas referencias bibliográficas consultadas, donde son usadas para el análisis de potenciales evocados. La selección de la wavelet *haar*, respondió al hecho de que su morfología no se encuentra correlacionada con la morfología de un potencial evocado. Como primera instancia vale aclarar que el cálculo de la correlación de las wavelet madres con el potencial evocado no es posible, porque no se tiene de antemano un potencial evocado para realizar este estimado. Se decide entonces calcular los valores *RMS* (ver Anexo 1) de la señal reconstruida para los cuatro casos con

los coeficientes seleccionados. Luego de calcular el valor *RMS*, se realizó un análisis ANOVA entre los resultados para determinar si existían diferencias significativas entre estos valores. El análisis reportó que no existían diferencias significativas. Este análisis sugiere utilizar cualquiera de las 4 wavelet para realizar la descomposición, no obstante se decide utilizar *coif4*, porque preserva las características deseadas de señal y la media de los valores *RMS* calculados es ligeramente superior aunque no es significativo.

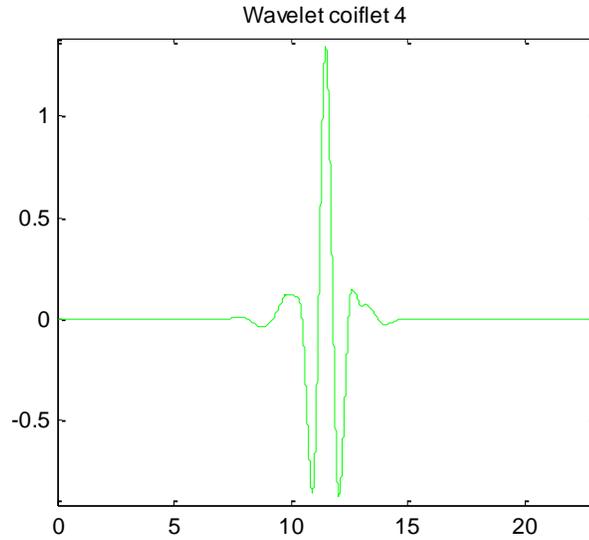


Figura 2. 6. Wavelet madre empleada para realizar la descomposición.

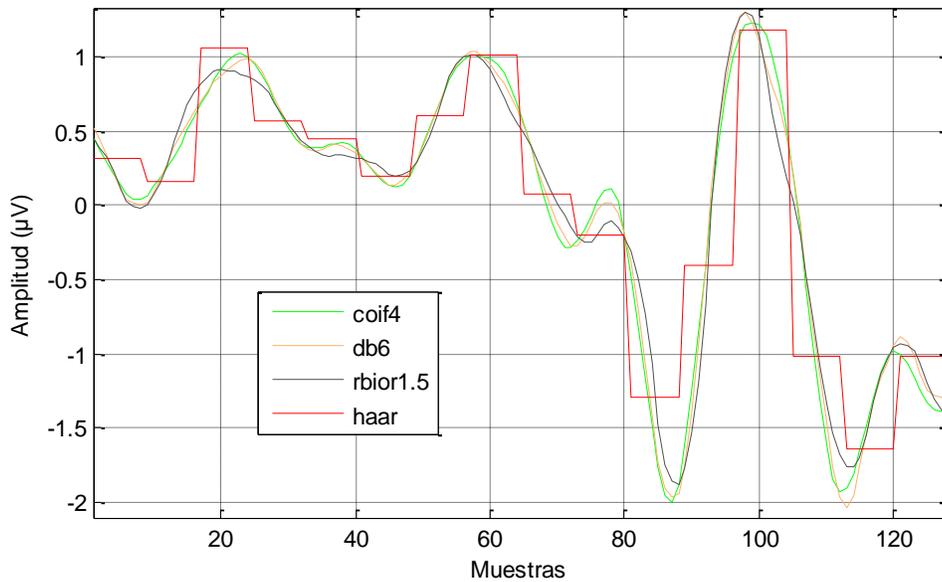


Figura 2. 7. Señales obtenidas utilizando las 4 wavelet madres.

Utilizando la herramienta *wavemenu* de Matlab, como se muestra en la Figura 2. 8, se obtiene una muestra de cómo queda la señal y su descomposición. Como se puede apreciar en los detalles  $d_4$  y  $d_5$  se evidencia claramente la morfología del potencial evocado, esto coincide con la descomposición en bandas de frecuencias asociados a estos detalles que quedan recogidas en la Figura 2. 5.

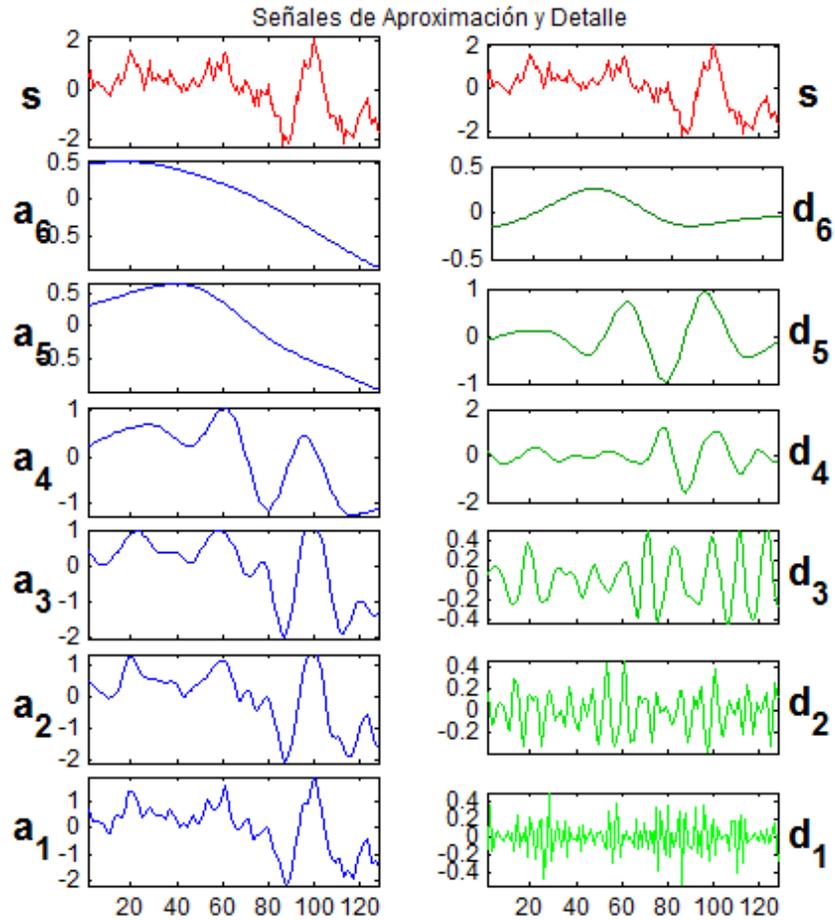


Figura 2. 8. Descomposición wavelet usando *coif4* y 6 niveles de descomposición.

Con el fin de realizar la descomposición de las señales se utiliza la función *wavedec* de Matlab. Esta función permite realizar la descomposición multinivel de una señal.

$[C, L] = \text{wavedec}(X, N, 'wname')$ , *wavedec* devuelve la descomposición de una señal  $X$ , en  $N$  niveles de descomposición utilizando una wavelet madre que es definida en 'wname'. Los vectores de salida  $C$  y  $L$  contienen la estructura de la descomposición, en  $C$  se encuentran los coeficientes y en  $L$  la longitud de cada conjunto de coeficientes para cada nivel de descomposición. Con la ayuda de esta función se descomponen las señales y se

obtienen los coeficientes que interesan. Los coeficientes escogidos son almacenados para todos los casos en un Excel con el fin de construir una base de datos que será utilizada en la etapa de clasificación.

La data obtenida está compuesta por 54 conjuntos de coeficientes de 74 coeficientes cada uno, 27 conjuntos corresponden a coeficientes de respuestas *target* y 27 a no *target*.

## 2.5 Clasificación de señales *target* y no *target* con Redes Neuronales BP

La propagación hacia atrás de errores o retropropagación (del inglés *backpropagation*) es un algoritmo de aprendizaje supervisado que se usa para entrenar redes neuronales artificiales. El algoritmo emplea un ciclo propagación – adaptación de dos fases. Una vez que se ha aplicado un patrón a la entrada de la red como estímulo, este se propaga desde la primera capa a través de las capas superiores de la red, hasta generar una salida. La señal de salida se compara con la salida deseada y se calcula una señal de error para cada una de las salidas. El desarrollo del experimento para la clasificación se realiza utilizando el toolbox de Matlab para Redes Neuronales. Este toolbox ofrece herramientas para el diseño, la implementación, la visualización y la simulación de redes neuronales.

Para definir un problema de reconocimiento de patrones, como en este caso; para posibilitar el reconocimiento entre dos clases es necesario organizar un conjunto de vectores de entrada como columnas en una matriz. Luego organizar otro conjunto de vectores objetivo de manera que indican las clases a las que se asignan los vectores de entrada. En este caso la data obtenida en la sección anterior es modificada con este fin, se le adicionan dos columnas que indiquen las clases a la que corresponde cada conjunto de coeficientes.

La data queda compuesta por un grupo de vectores de entrada que corresponden a los rasgos (coeficientes wavelet seleccionados) y vectores denominados *Target*, que en este caso no se refiere a la misma definición de *target* utilizada anteriormente para definir la presencia o no de respuesta a un elemento diana, sino del vector que contendrá la clasificación de las clases de cada uno de los vectores de entrada.

Tabla 2. 2. Organización de la data para realizar la clasificación utilizando Redes Neuronales

Vectores de Entrada					Vectores <i>Target</i>	
Rasgo 1	Rasgo 2	Rasgo 3	...	Rasgo n	Clase	Clase
Coef1.1	Coef1.2	Coef1.3	...	Coef1.n	1	0
Coef2.1	Coef2.2	Coef2.3	...	Coef2.n	1	0
Coef3.1	Coef3.2	Coef3.3	...	Coef3.n	0	1
Coef4.1	Coef4.2	Coef4.3	...	Coef4.n	0	1
⋮	⋮	⋮	⋮	⋮	⋮	⋮
Coefm.n	Coefm.n	Coefm.n	...	Coefm.n	1	0

Problemas de clasificación como este implican solamente dos clases y estas pueden ser representadas en cualquier formato. En este caso se utilizó vectores de dos elementos 1 y 0, como se puede apreciar en las dos últimas columnas de la Tabla 2. 2.

### 2.5.1 Herramienta *nprtool*

Esta sección muestra cómo entrenar una red para reconocer patrones, utilizando la interfaz gráfica de redes neuronales, herramienta de reconocimiento de patrones, *nprtool* de Matlab.

Esta herramienta permite obtener una red de alimentación directa (*feedforward*) caracterizada por:

- Una capa de entrada que tiene tantas unidades como atributos
- Una o varias capas ocultas (cuando el número de unidades ocultas es más grande el modelo extraído por la red neuronal es más compleja - pero esto no es necesariamente beneficiosa para resolver el problema)
- Una capa de salida que tiene tantas unidades como clases sean dadas.
- Función de transferencia *logsig*, donde  $a = \text{logsig}(n)$ .

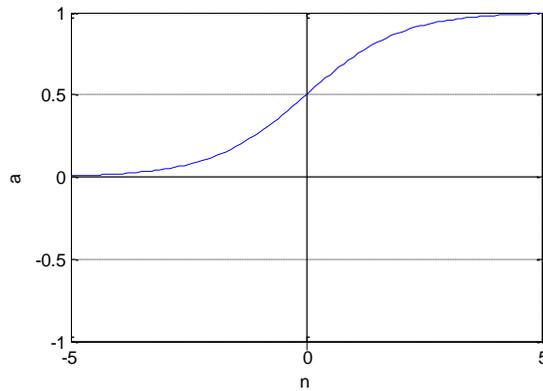


Figura 2. 9. Función de transferencia logsig.

- Algoritmo de retropropagación de errores (*backpropagation*).

El proceso de aprendizaje es controlado por una técnica de validación cruzada que consiste en dividir el conjunto inicial de datos en tres partes:

Datos para Entrenamiento: Datos utilizados en el algoritmo de entrenamiento para calcular los ajustes de los pesos de las conexiones.

Datos para Validación: Cuando el error de clasificación comienza a aumentar, se detiene el proceso de entrenamiento (estos datos no se utilizan para calcular los ajustes de pesos, sólo para decidir si la red tiene capacidad de generalización o no).

Datos para Prueba: Estos datos no se utilizan en el proceso de entrenamiento, sólo para evaluar la calidad del clasificador

La calidad del clasificador (diseñado para identificar dos clases) se mide mediante el cómputo de la matriz de confusión y por lo que representa la gráfica de la curva ROC (ROC).

### 2.5.2 Matriz de confusión

La matriz de confusión contiene información sobre el porcentaje de datos que fueron correctamente / incorrectamente clasificados. La matriz de confusión contiene número de casos que:

Verdaderos Positivos (TP, de sus siglas en inglés): Número de casos de la primera clase clasificados como de la primera clase.

Verdaderos Negativos (TN, de sus siglas en inglés): Número de casos de la segunda clase que son correctamente clasificados como de la segunda clase.

Falsos Positivos (FP, de sus siglas en inglés): Casos de la primera clase que son incorrectamente clasificados como de la segunda clase.

Falsos Negativos (FN, de sus siglas en inglés): Casos de la segunda clase que fueron clasificados incorrectamente como de la primera clase.

A partir de estas medidas se pueden obtener otras como:

$$\text{Sensibilidad} = TP / (TP + FN)$$

$$\text{Especificidad} = TN / (TN + FP)$$

$$\text{Precisión} = TP / (TP + FP)$$

$$\text{Valor de Predicción Negativo} = TN / (TN + FN)$$

$$\text{Exactitud} = (TP + TN) / P + N,$$

entre otras.

La Figura 2. 10 muestra las matrices de confusión que devuelve la herramienta para cada juego de datos.



Figura 2. 10. Matrices de confusión para cada juego de datos.

### 2.5.3 Curva ROC

La curva ROC (acrónimo de *Receiver Operating Characteristic*). La cual es una representación gráfica de la sensibilidad frente a  $(1 - \text{especificidad})$  para un sistema clasificador binario según se varía el umbral de discriminación. Contiene una diagonal de referencia o línea de no discriminación, trazada desde la coordenada 0,0 hasta 1,1. Esta línea describe cuando un test es capaz de clases de dos tipos. Un clasificador será mejor si es capaz de trazar una curva lo más alejada posible de la línea de no discriminación, lo más cercana posible al extremos superior izquierdo. La Figura 2. 11 muestra cómo se deben ver estas en una clasificación perfecta.

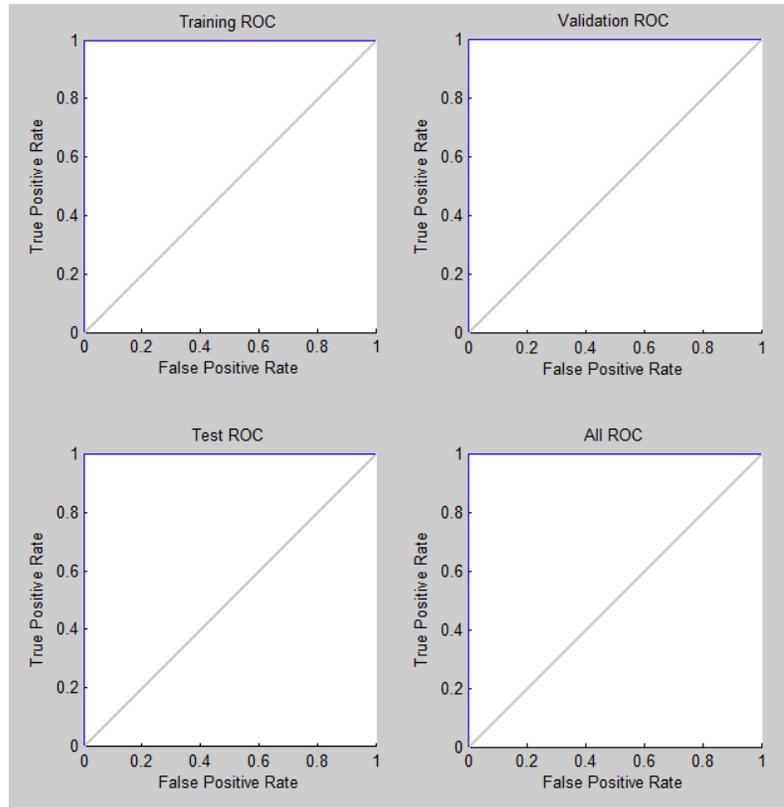


Figura 2. 11. Curvas ROC dadas en *nprtool*

A partir de la explicación de la herramienta *nprtool* la siguiente sección explica cómo queda el experimento.

#### 2.5.4 Creación de la red y entrenamiento

Los datos son divididos aleatoriamente en tres grupos, un por ciento para clasificar otro para validar y otro para probar. Inicialmente la red se mantuvo con la división ofrecida por la herramienta por defecto, un 75 % (38 muestras) de los datos para entrenar, un 15 % (8 muestras) para validar y un 15 % (8 muestras) para probar, esta división la hace de forma aleatoria. La red queda como se muestra en la siguiente figura, se mantuvo también el número inicial de neuronas en la capa oculta que sugiere la herramienta, 10 (ver Figura 2. 12). Luego se procede a entrenar la red. Al finalizar la red se obtienen un conjunto de información (matrices de confusión y curvas ROC) que sirve para caracterizar el comportamiento de la red y de la clasificación.

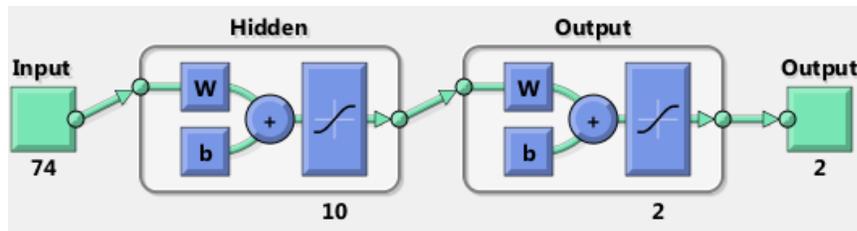


Figura 2. 12. Diseño de la red.

La herramienta permite además validar la red con nuevos datos y ver así si esta es suficientemente buena, en este punto, se puede probar la red contra los nuevos datos. Si no se está satisfecho con el rendimiento de la red con los datos originales o nuevos, se puede entrenar de nuevo, aumentar el número de neuronas, o tal vez obtener un conjunto de datos de entrenamiento más grande. Si el rendimiento en el conjunto de entrenamiento es bueno, pero el rendimiento de prueba es significativamente peor, lo que podría indicar sobreajuste, entonces la reducción del número de neuronas puede mejorar los resultados. Estos elementos descritos en esta parte se realizan en la siguiente ventana.

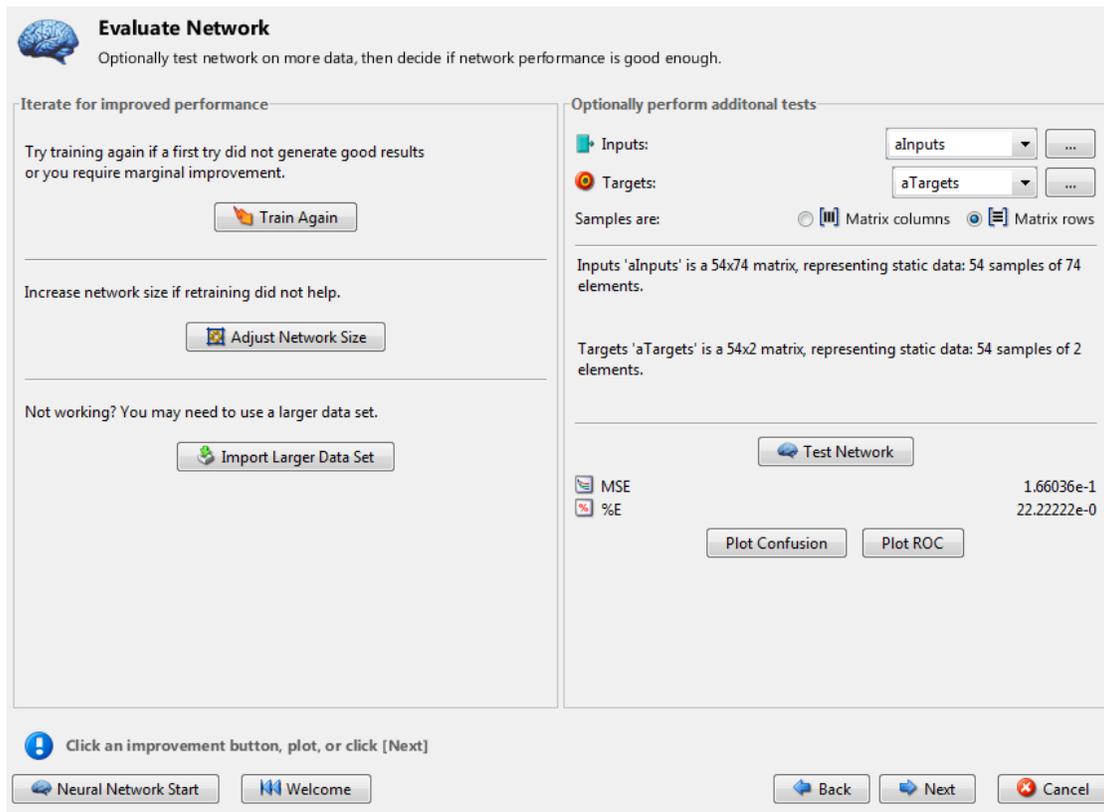


Figura 2. 13. Interfaz que permite evaluar la red.

Cuando se está completamente satisfecho con el desempeño de la red la interfaz permite salvar los resultados y además salvar un *script* simple y uno avanzado, que contienen el código de Matlab que permite reproducir los pasos anteriores y además hacer otras modificaciones a algunas variables o funciones que están predefinidas en la herramienta gráfica.

Llegando a este punto es importante explicar que la función que se dedica a construir la red se denomina *patternnet*.

**patternnet (hiddenSizes, trainFcn)**, permite diseñar la red definiendo el número de neuronas en la capa oculta, *hiddenSizes* y la función de entrenamiento, *trainFcn*.

La función de entrenamiento que se utiliza es 'trainlm', por defecto. La función *trainlm* es a menudo el algoritmo *backpropagation* más rápido de la caja de herramientas, y es recomendable como primera elección, aunque requiere más memoria que otros algoritmos. Se basa en el algoritmo de optimización de Levenberg-Marquardt[68].

Se decide utilizar en nuestro experimento además la función de entrenamiento 'trainrp', esta función de entrenamiento actualiza los valores de peso y de polarización de acuerdo con el algoritmo de retropropagación elástica [69]. Este algoritmo es similar al regular, pero tiene como ventajas que a menudo es mucho más rápido y no se necesita que se especifiquen los parámetros libres (tasa de aprendizaje). La modificación de la función **patternnet** con el fin de utilizar esta otra función de entrenamiento se realiza en el *script* simple salvado.

## 2.6 Conclusiones del Capítulo

En este Capítulo se utilizaron herramienta y métodos con el fin de organizar una data compuesta por los coeficientes wavelet obtenidos de respuestas a caracteres dianas y no dianas de 12 sujetos. Se realizó una breve comparación entre wavelet madres que permitió la selección de una de ellas con el fin de realizar la conformación de la data. La data fue organizada de forma tal que permita la clasificación en dos clases, respuestas *target* o no *target* con el uso de una red neuronal. Los aspectos relacionados con el diseño de una red neuronal utilizando las herramientas graficas de Matlab también fueron tomados en cuenta en este capítulo. Se concluyó utilizar una wavelet madre coif4 para realizar la selección de los coeficientes y diseñar una red con 10 neuronas en la capa oculta utilizando dos funciones para el entrenamiento. En el Capítulo siguiente queda recogida la discusión de los resultados obtenidos en este experimento.

## CAPÍTULO 3. RESULTADOS Y DISCUSIÓN

En este capítulo se muestran los resultados obtenidos de la clasificación en respuestas *target* y no *target* de las señales obtenidas de la base de datos. Como primer paso fue necesario obtener los rasgos, para esto se usó la transformada discreta wavelet. Luego de extraer los coeficientes, se conformó una data que permitiera realizar la clasificación. Los resultados obtenidos en cada uno de estos momentos son recogidos en este capítulo.

### 3.1 Obtención de coeficientes utilizando transformada discreta wavelet.

La siguiente tabla muestra los valores RMS de las señales *target* reconstruidas a partir de los 74 coeficientes pertenecientes a A6, D6, D5 y D4, obtenidos con cuatro wavelet madres diferentes.

Tabla 3. 1. Valores RMS de la señal reconstruida con cuatro wavelet madres diferentes

	coif4	db6	rbio1.5	haar
P1_1	8.85796538	8.85409488	8.76973129	8.655754
P2_1	9.36393836	9.35600762	9.31572594	9.06338749
P3_1	10.0808122	9.99780366	9.58072541	9.46669196
P4_1	9.78738639	9.8120089	9.75471343	9.42311348
P5_1	9.32987571	9.15410622	9.20127853	9.07126724
P6_1	9.18826371	9.13096838	9.00628526	8.87918093
P7_1	9.45746184	9.50353576	9.73772036	9.0744507
P8_1	9.82113094	9.6614594	9.64681343	9.6323867
P9_1	1.73148492	1.84693137	3.16849575	2.91518884

P10_1	6.37519287	6.31779473	6.27796251	6.14377566
P11_1	9.93787033	9.79330075	9.93052257	9.71489429
P12_1	10.6566223	10.6208594	10.6348743	10.5032804
P1_2	8.6837653	8.63338438	8.61837588	7.96006383
P2_2	9.33397535	9.30548515	9.31440894	8.92716817
P3_2	10.1236845	10.058274	9.61970649	9.31200364
P4_2	9.71067868	9.70058901	9.82569995	9.30922332
P5_2	47.7065247	47.7113084	47.8176175	47.3196969
P6_2	9.33277627	9.29043386	9.2960494	9.3544555
P7_2	6.93826935	7.00058816	6.93356196	7.26220401
P8_2	7.38764305	7.43061967	7.60470083	7.1379593
P9_2	3.02773378	3.09424134	4.06030369	3.96972393
P10_2	6.34805305	6.27230169	6.38045317	5.76585956
P11_2	8.68313012	8.3383349	7.85273792	8.62034378

Para ver si existían diferencias se realizó un test ANOVA, el cual compara las medias de 2 o más columnas de una data. Cada columna representa una muestra independiente de una observación. Como se observa en la Figura 3. 1, a simple vista no se muestran diferencias significativas. Esta asunción lo reafirma la Tabla ANOVA obtenida y mostrada en la figura Figura 3. 2, donde se obtiene un valor alto de  $p = 0.997$ , en este caso se acepta la hipótesis nula, planteada en esta prueba, que dice que todas las observaciones tienen igual media. Por lo que se seleccionó `coif4`, la media de los valores es mínimamente mayor que la de las otras. La Figura 2. 7 muestra un ejemplo de una señal reconstruida utilizando los coeficientes seleccionados, aunque el resultado estadístico como se ve anteriormente no muestra diferencias significativas, en las señales reconstruidas, la haar muestra los peores resultados.

A partir del análisis previo hecho se decidió utilizar `coief4` para la obtención de los coeficientes.

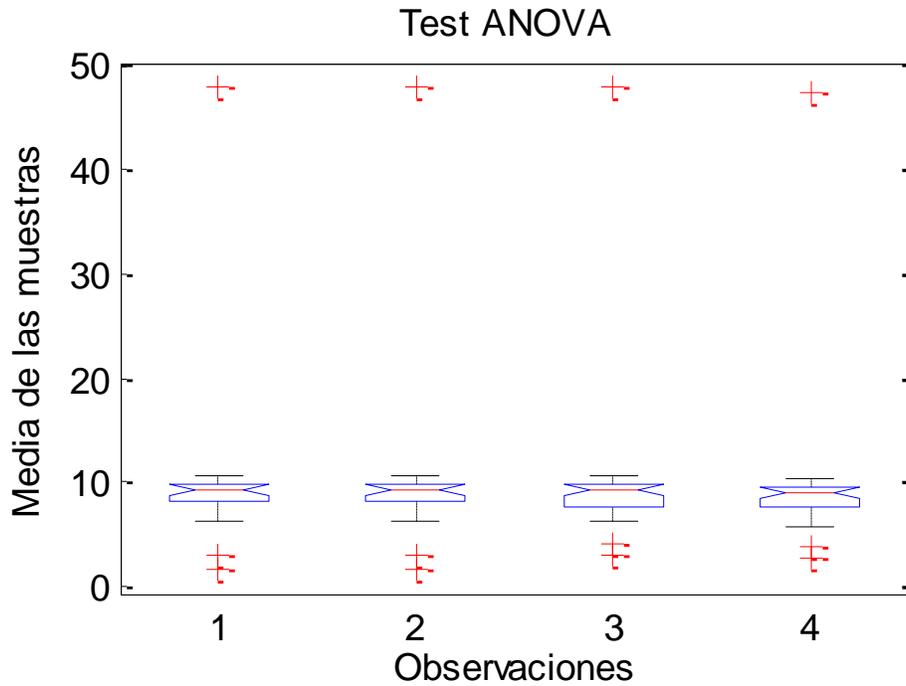


Figura 3. 1. Test ANOVA para determinar diferencias entre el resultado obtenido entre las 4 wavelet madres.

<b>ANOVA Table</b>					
Source	SS	df	MS	F	Prob>F
Columns	0.73	3	0.244	0	0.9997
Error	6287.8	96	65.4979		
Total	6288.53	99			

Figura 3. 2. Tabla ANOVA, un valor de  $p$  cercano a uno indica se acepta la hipótesis nula.

### 3.2 Señales obtenidas mediante promediado y reconstrucción wavelet.

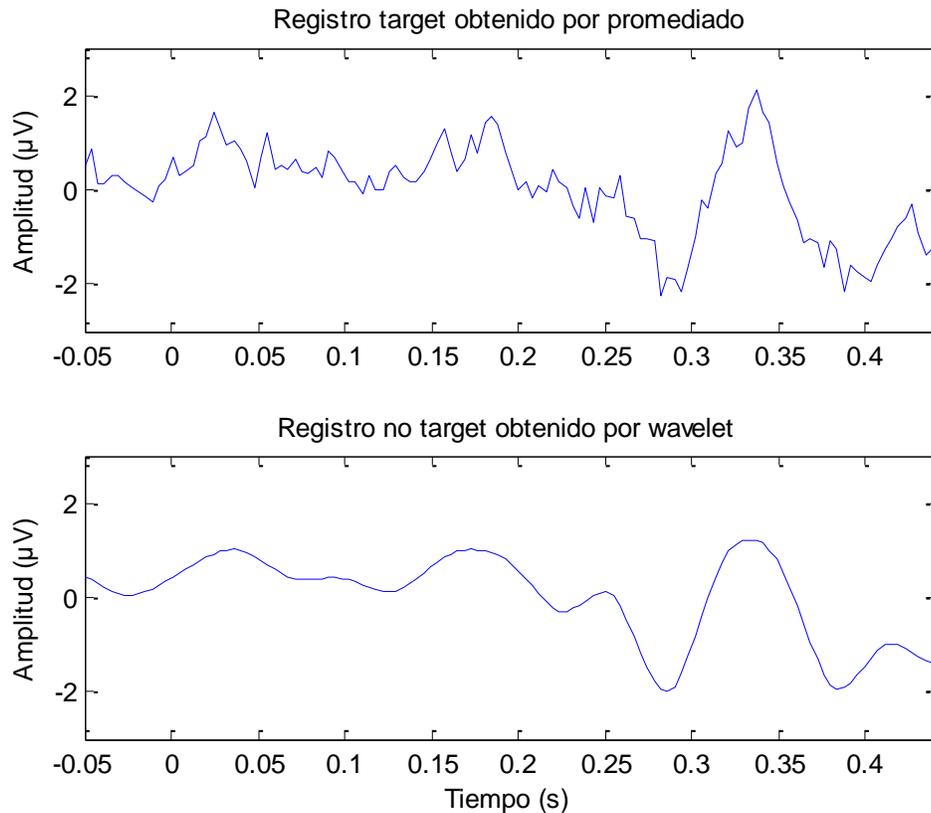


Figura 3. 3. Respuesta *target* obtenida con promediado y con wavelet.

Las figuras 3.3 y 3.4 muestran un ejemplo de señales obtenidas mediante la reconstrucción wavelet a partir de los coeficientes seleccionados. La primera de estas corresponde a la señal correspondiente a la respuesta al *target* y la segunda a la respuesta al no *target*. Además cada figura consta de dos imágenes, la primera corresponde a la señal obtenida solo utilizando el método de promediado, como se puede observar estas señales aún están contaminadas con ruido, no permitiendo la identificación correcta de las ondas típicas que caracterizan un Potencial Evocado Cognitivo Visual, no siendo así en la señal reconstruida utilizando los coeficientes wavelet.

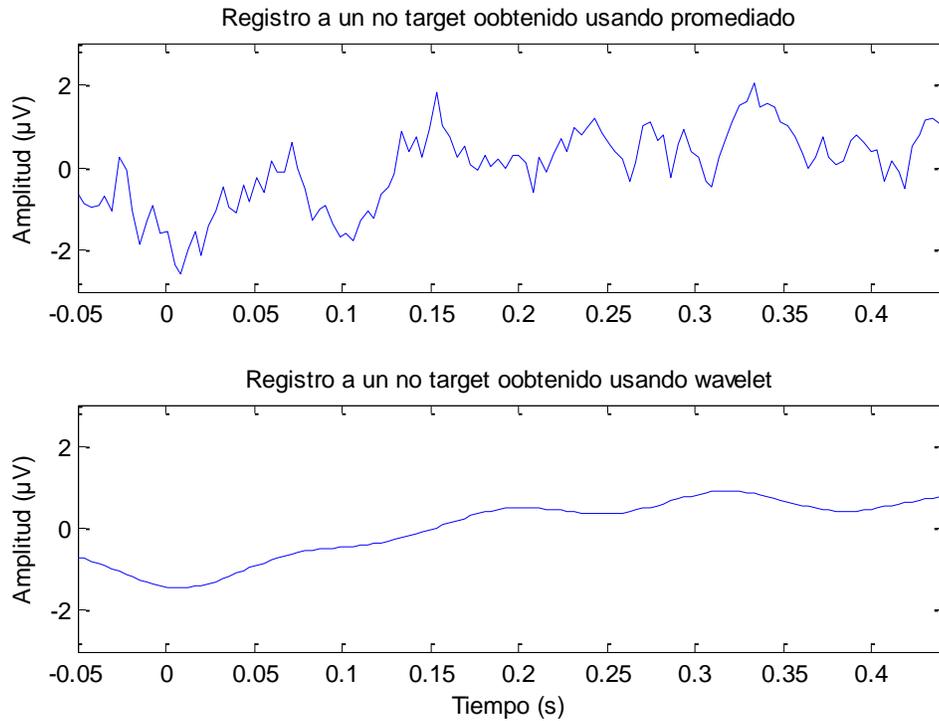


Figura 3. 4 Respuesta no *target* obtenida con promediado y con wavelet.

### 3.3 Clasificación utilizando redes neuronales

Los datos siguientes muestran los resultados obtenidos, utilizando dos redes, una con 10 neuronas en la capa oculta y otra con 20. En ambos casos se utilizaron las dos funciones de entrenamiento, 'trainlm', dada por defecto y 'trainrp', ambas pertenecientes a dos algoritmos de entrenamiento *backpropagation* contenidos en Matlab. Para todos los casos se mantuvo la división aleatoria de las muestras en un 75% de muestras para entrenar, 15% para validar y 15% para probar. Como se puede ver tanto en las figuras mostradas a continuación como en la Tabla 3. 2, se obtienen buenas tasas de clasificación para todos los casos. No obstante el mejor compromiso lo muestra la red de 20 neuronas utilizando la función de entrenamiento 'trainrp'. Es necesario aclarar que nuestra data es una data balanceada. Si comparamos los resultados obtenidos en este trabajo con los obtenidos en [3], donde la tasa de clasificación es de un 85 % de clasificación correcta para una data desbalanceada (15 juego de datos con presencia de PEV y 5 no), podemos decir que los obtenidos en este trabajo son superiores. No obstante si desbalanceamos nuestra data a una misma razón que la dada en [3], en este caso 27 juegos de coeficientes correspondientes a

respuestas *target* y 9 correspondientes a no *target* , obtenemos como resultado la matriz de confusión mostrada en la Figura 3. 13. Igualmente se muestra que la tasa de clasificación es superior.

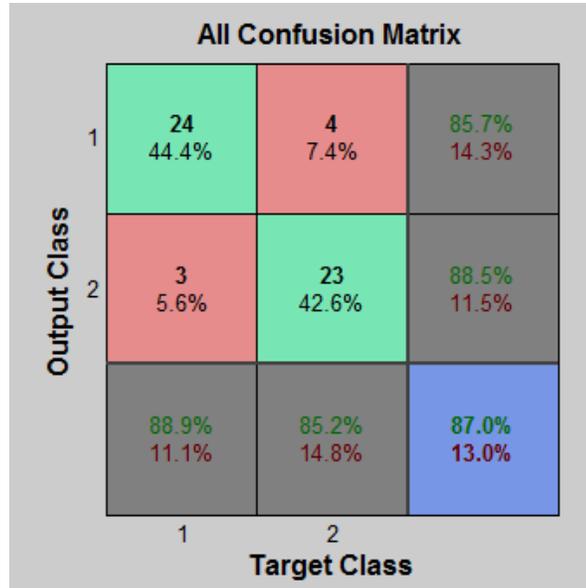


Figura 3. 5. Matriz de confusión para una red de 10 neuronas ocultas con ‘trainlm’.

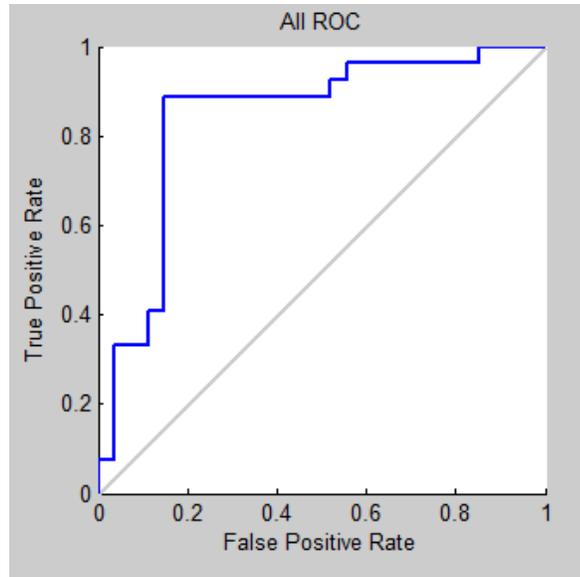


Figura 3. 6. Curva ROC obtenida para una red de 10 neuronas ocultas con ‘trainlm’.

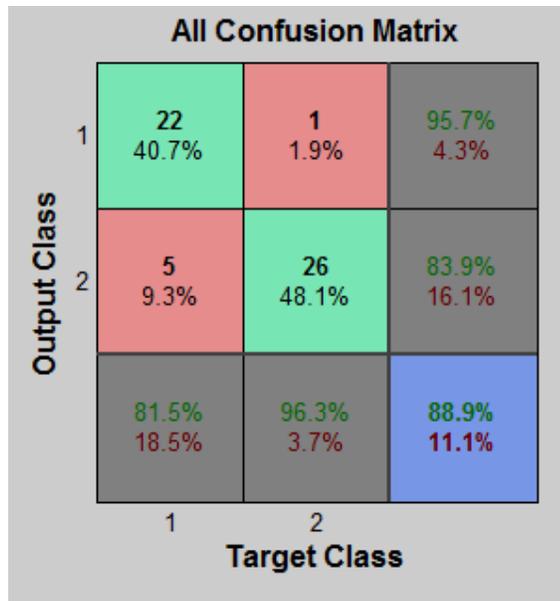


Figura 3. 7. Matriz de confusión para una red de 20 neuronas ocultas con ‘trainlm’

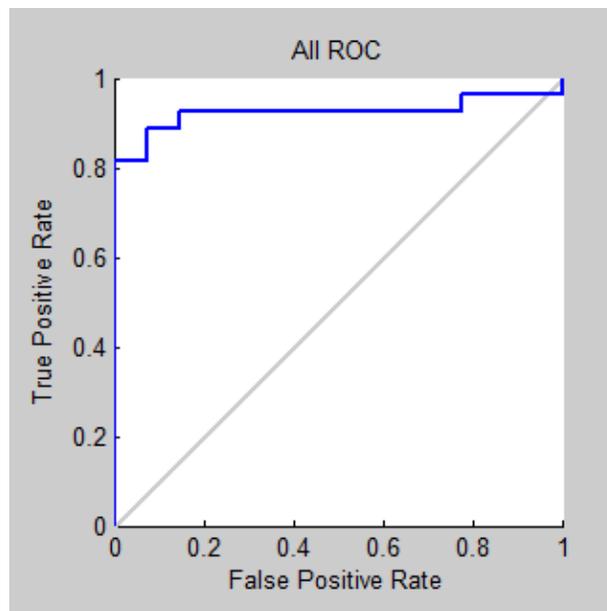


Figura 3. 8. Curva ROC obtenida para una red de 20 neuronas ocultas con ‘trainlm’.

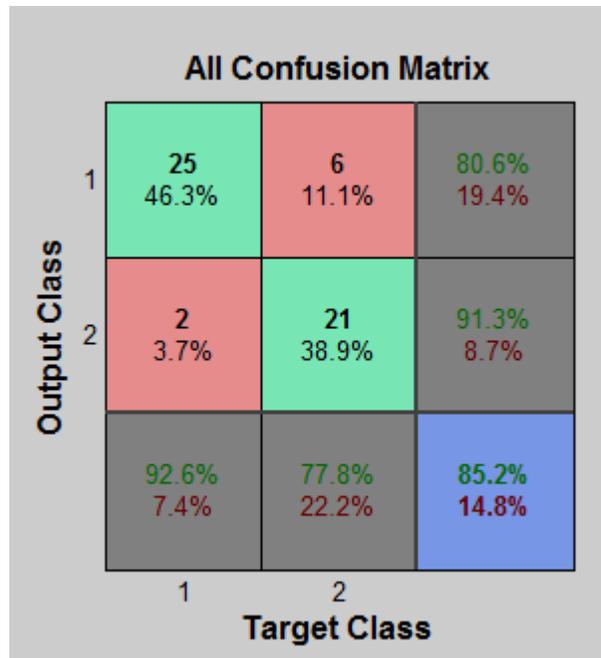


Figura 3. 9. Matriz de confusión para una red de 10 neuronas ocultas con ‘trainrp’.

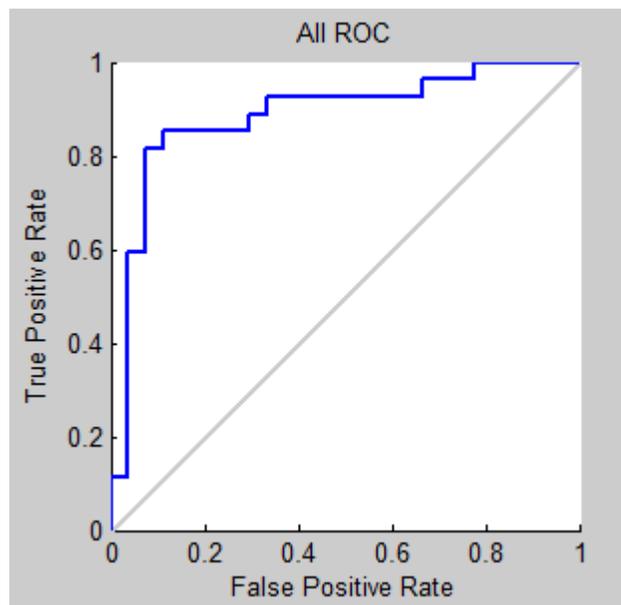


Figura 3. 10. Curva ROC obtenida para una red de 10 neuronas ocultas con ‘trainrp’.

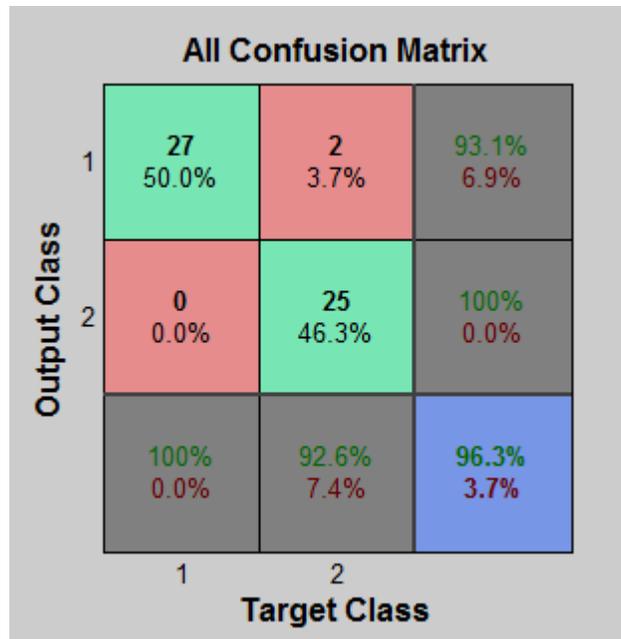


Figura 3. 11. Matriz de confusión para una red de 20 neuronas ocultas con 'trainrp'.

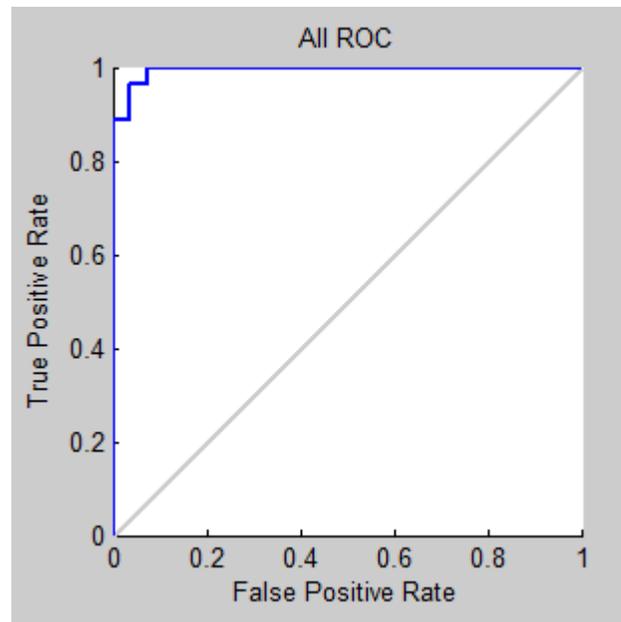


Figura 3. 12. Curva ROC obtenida para una red de 20 neuronas ocultas con 'trainrp'.

Tabla 3. 2. Índices de desempeño calculados a partir de las matrices de confusión encontradas.

Índices de desempeño	10 neuronas	20 neuronas	10 neuronas	20 neuronas
	trainlm	trainlm	trainrp	trainrp
Sensibilidad	88,9 %	81,5 %	92,6 %	100 %
Especificidad	85,2 %	96,3 %	77,8 %	92,6 %
Precisión	85,7 %	95,7 %	80,6 %	93,1 %
Valor de Predicción Negativo	88,5 %	83,9 %	91,3 %	100 %
Exactitud	87,7 %	88,9 %	85,2 %	96,3 %

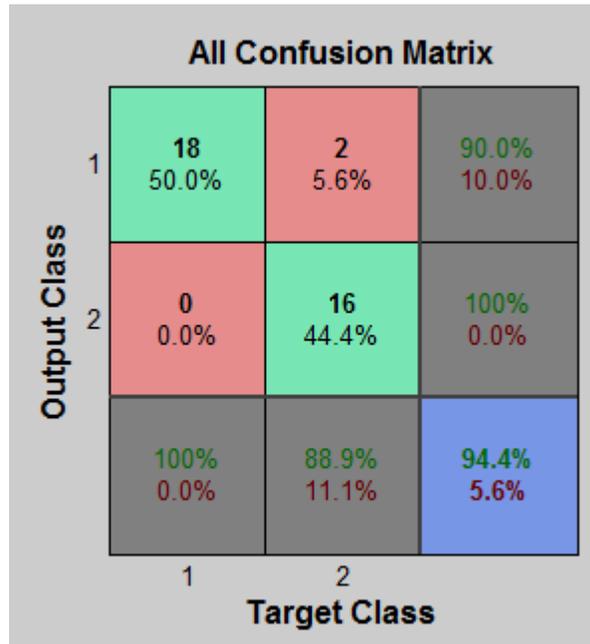


Figura 3. 13. Matriz de confusión para red con 20 neuronas y función ‘trainrp’ para data desbalanceada.

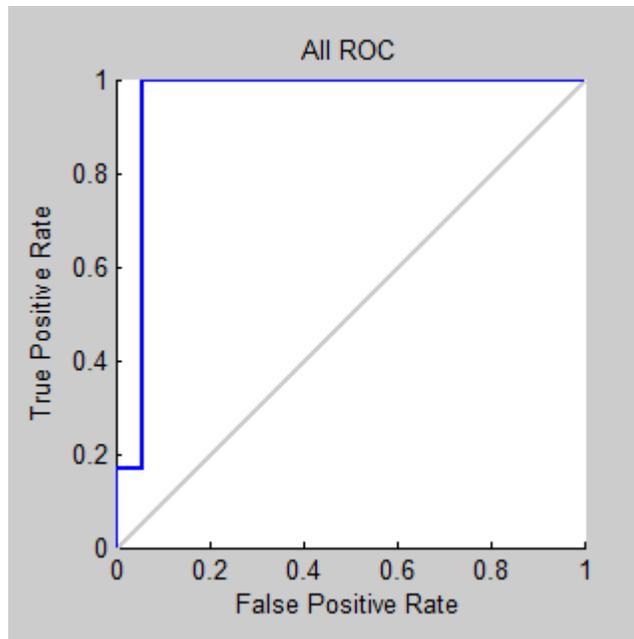


Figura 3. 14. Curvas ROC para red con 20 neuronas y función 'trainrp' para data desbalanceada.

Tabla 3. 3. Índices de desempeño calculados a partir de las matrices de confusión encontradas para data desbalanceada.

Índices de desempeño	20 neuronas trainrp
Sensibilidad	100 %
Especificidad	88,9 %
Precisión	90,0 %
Valor de Predicción Negativo	100%
Exactitud	94,4%

## CONCLUSIONES Y RECOMENDACIONES

### Conclusiones

En el desarrollo de este trabajo se comprobó que:

- La Base de Datos reportada en Physionet, basada en un deletreador Donchin puede ser usada con fines académicos, para la experimentación y análisis de distintas técnicas de detección y reconocimiento de Potenciales Evocados Cognitivos
- A partir de un análisis para 4 wavelet madres, se determinó que la wavelet coif4 se ajusta mejor a las características de estas señales, por lo que se comprobó que es posible la detección de PE utilizando Transformada Wavelet.
- Los coeficientes seleccionados, correspondientes principalmente a los ritmos, delta, theta y alfa pueden ser usadas como rasgos en la etapa de clasificación.
- Los coeficientes seleccionados pueden ser usados en la creación de una data para clasificar respuestas a *target* a *no target*.
- La clasificación en respuestas *target* y *no target* es posible realizarla con Redes Neuronales, en este caso los mejores resultados fueron ofrecidos con 20 neuronas en la capa oculta y función de entrenamiento 'trainrp', obteniendo valores de clasificación del 96,3 %.
- Para una data desbalanceada, utilizando la misma razón que la propuesta en [3] se obtuvieron incluso mejores resultados.

### Recomendaciones

A partir del trabajo desarrollado y los resultados obtenidos se recomienda:

- 1 Probar con un número mayor de wavelet madres para seleccionar diferentes conjuntos de coeficientes para realizar la clasificación y el análisis estadístico de los resultados.
- 2 Probar los resultados de la clasificación utilizando otras funciones de entrenamiento propuestas en el propio Matlab y en la literatura.
- 3 Realizar la clasificación utilizando otros métodos, como el Coeficiente de Pearson y el Discriminante Lineal de Fisher y comparar los resultados con los obtenidos en este trabajo.

**REFERENCIAS BIBLIOGRÁFICAS**

- [1] N. B. Jonathan R. Wolpaw, William J. Heetderks, Dennis J. McFarland, P. Hunter Peckham, and E. D. Gerwin Schalk, Louis A. Quatrano, Charles J. Robinson, and Theresa M. Vaughan "Brain-Computer Interface Technology: A Review of the First International Meeting," *IEEE TRANSACTIONS ON REHABILITATION ENGINEERING*, vol. 8, pp. 164-173, 2000.
- [2] E. Donchin, *et al.*, "The mental prosthesis: assessing the speed of a P300-based brain-computer interface," *Rehabilitation Engineering, IEEE Transactions on*, vol. 8, pp. 174-179, 2000.
- [3] L. Yu and T. Meng, "The Recognition of Visual Evoked Potential Based on Wavelet Transformation and BP Neural Network," in *Intelligent Computation Technology and Automation, 2009. ICICTA'09. Second International Conference on*, 2009, pp. 117-120.
- [4] L. Sörnmo and P. Laguna, *Bioelectrical signal processing in cardiac and neurological applications*: Academic Press, 2005.
- [5] P. A. C. Cabrera, "Extracción y Selección de Características Discriminantes para la Detección de TDAH en Registros de Potenciales Evocados Cognitivos," Universidad Nacional de Colombia - Sede Manizales, Departamento de Ingeniería Eléctrica, Electrónica y Computación, Universidad Nacional de Colombia - Sede Manizales, Manizales, Colombia, 2011.
- [6] H. Cecotti and A. Gräser, "Convolutional neural networks for P300 detection with application to brain-computer interfaces," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 33, pp. 433-445, 2011.
- [7] C. W. Anderson, *et al.*, "Determining mental state from EEG signals using parallel implementations of neural networks," *Scientific programming*, vol. 4, pp. 171-183, 1995.
- [8] H. Cecotti and A. Graser, "Time Delay Neural Network with Fourier transform for multiple channel detection of Steady-State Visual Evoked Potentials for Brain-Computer Interfaces," in *Signal Processing Conference, 2008 16th European*, 2008, pp. 1-5.

- 
- [9] T. Felzer and B. Freisieben, "Analyzing EEG signals using the probability estimating guarded neural classifier," *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, vol. 11, pp. 361-371, 2003.
- [10] E. Haselsteiner and G. Pfurtscheller, "Using time-dependent neural networks for EEG classification," *Rehabilitation Engineering, IEEE Transactions on*, vol. 8, pp. 457-463, 2000.
- [11] N. Masic and G. Pfurtscheller, "Neural network based classification of single-trial EEG data," *Artificial Intelligence in Medicine*, vol. 5, pp. 503-513, 1993.
- [12] N. Masic, *et al.*, "Neural network-based predictions of hand movements using simulated and real EEG data," *Neurocomputing*, vol. 7, pp. 259-274, 1995.
- [13] B. Blankertz, *et al.*, "Classifying single trial EEG: Towards brain computer interfacing," *Advances in neural information processing systems*, vol. 1, pp. 157-164, 2002.
- [14] A. Rakotomamonjy and V. Guigue, "BCI competition III: dataset II-ensemble of SVMs for BCI P300 speller," *Biomedical Engineering, IEEE Transactions on*, vol. 55, pp. 1147-1154, 2008.
- [15] B. Obermaier, *et al.*, "Hidden Markov models for online classification of single trial EEG data," *Pattern recognition letters*, vol. 22, pp. 1299-1309, 2001.
- [16] S. Zhong and J. Ghosh, "HMMs and coupled HMMs for multi-channel EEG classification," in *Proceedings of the IEEE International Joint Conference on Neural Networks*, 2002, pp. 1254-1159.
- [17] A. Hiraiwa, *et al.*, "EEG topography recognition by neural networks," *Engineering in Medicine and Biology Magazine, IEEE*, vol. 9, pp. 39-42, 1990.
- [18] E. Rodríguez, "Enseñanza de la Ingeniería Biomédica en Cuba," *Centro*, vol. 602, p. 4, 2003.
- [19] M. d. C. S. Panicles, "Registro de los potenciales evocados: aproximación a los componentes P300 y N400," *Revista de psicología general y aplicada: Revista de la Federación Española de Asociaciones de Psicología*, vol. 44, pp. 317-322, 1991.
- [20] M. Lang and T. Mitrovic, "Investigating the Emotiv EPOC for cognitive control in limited training time," *Honours report, University of Canterbury*, p. 8, 2012.
- [21] M. A. Simón and E. Amenedo, *Manual de psicofisiología clínica*: Pirámide, 2001.
- [22] Z. Xu, *et al.*, "Steady-state visually evoked potential (SSVEP)-based brain-computer interface (BCI): a low-delayed asynchronous wheelchair control system," in *Neural Information Processing*, 2012, pp. 305-314.
- [23] M. Cheng, *et al.*, "Design and implementation of a brain-computer interface with high transfer rates," *Biomedical Engineering, IEEE Transactions on*, vol. 49, pp. 1181-1186, 2002.
- [24] K. H. Chiappa, *Evoked potentials in clinical medicine*: Lippincott Williams & Wilkins, 1997.

- [25] F. Z. Castro, *et al.*, "La adaptación audioprotésica pediátrica precoz a partir de registros de potenciales evocados auditivos de estado estable," *Acta Otorrinolaringologica Espanola*, vol. 57, pp. 388-393, 2006.
- [26] A. Herrera, *et al.*, "Estimación de potenciales evocados auditivos mediante transformada wavelet y descomposición modal empírica, un estudio comparativo," *Scientia et Technica*, vol. 3, pp. 240-245, 2008.
- [27] C. Machado Curbelo, *et al.*, "Potenciales evocados visuales y el electroretinograma en la muerte encefálica," *Rev. cuba. oftalmol*, vol. 4, pp. 117-24, 1991.
- [28] N. A. Busch, *et al.*, "Size matters: effects of stimulus size, duration and eccentricity on the visual gamma-band response," *Clinical Neurophysiology*, vol. 115, pp. 1810-1820, 2004.
- [29] D. G. Volman, *et al.*, "Potenciales Evocados Somatosensoriales de corta latencia del nervio Tibial Posterior en población anciana sana.", 2006.
- [30] E. Delamónica and E. Delamonica, "Potenciales evocados somatosensitivos," *DELAMÓNICA, EA "Electroencefalografía". 2da. edición. El Ateneo, Buenos Aires, Argentina*, pp. 581-598, 1987.
- [31] C. J. Borrego, *et al.*, "Potenciales evocados motores," *Acta Médica Colombiana*, vol. 17, p. 2, 1992.
- [32] I. d. S. Jardim, *et al.*, "Emissões otoacústicas evocadas por estímulos transientes e potencial evocado auditivo de tronco encefálico automático na triagem auditiva neonatal," *Einstein (São Paulo)*, vol. 6, pp. 253-261, 2008.
- [33] R. Byring and T. Järvillehto, "Auditory and visual evoked potentials of schoolboys with spelling disabilities," *Developmental Medicine & Child Neurology*, vol. 27, pp. 141-148, 1985.
- [34] D. Torres Soriano, "Electrodiagnóstico: protocolo clínico y estandarización de Electroretinografía (ERG) y Potenciales Evocados Visuales (PEV) en el perro beagle," 2011.
- [35] H. H. Jasper, "The ten twenty electrode system of the international federation," *Electroencephalography and clinical neurophysiology*, vol. 10, pp. 371-375, 1958.
- [36] X. Gao, *et al.*, "A BCI-based environmental controller for the motion-disabled," *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, vol. 11, pp. 137-140, 2003.
- [37] H. J. Griffiths, "Encyclopedia of Medical Devices and Instrumentation," *Radiology*, vol. 170, pp. 1016-1016, 1989.
- [38] M. Idiazábal, *et al.*, "Potenciales evocados cognitivos en el trastorno por déficit de atención con hiperactividad," *Rev Neurol*, vol. 34, pp. 301-5, 2002.
- [39] R. J. Barry, *et al.*, "A review of electrophysiology in attention-deficit/hyperactivity disorder: II. Event-related potentials," *Clinical Neurophysiology*, vol. 114, pp. 184-198, 2003.

- [40] I. Hoonhorst, *et al.*, "N1b and Na subcomponents of the N100 long latency auditory evoked-potential: Neurophysiological correlates of voicing in French-speaking subjects," *Clinical neurophysiology*, vol. 120, pp. 897-903, 2009.
- [41] R. Näätänen and P. T. Michie, "Early selective-attention effects on the evoked potential: a critical review and reinterpretation," *Biological psychology*, vol. 8, pp. 81-136, 1979.
- [42] S. J. Luck, *An introduction to the event-related potential technique*: MIT press, 2014.
- [43] M. J. P. Herrero and M. A. M. Benedicto, "Trastorno por déficit de atención con hiperactividad y potenciales evocados cognitivos. Proyecto de investigación," *Fòrum de Recerca*, pp. 111-121, 1998.
- [44] S. H. Patel and P. N. Azzam, "Characterization of N200 and P300: selected studies of the event-related potential," *International Journal of Medical Sciences*, vol. 2, p. 147, 2005.
- [45] M. Lang, "Investigating the Emotiv EPOC for cognitive control in limited training time," *Dep of Comp Sci, Univ of Canterb*, 2012.
- [46] Z. Xu, *et al.*, "Steady-State Visually Evoked Potential (SSVEP)-Based Brain-Computer Interface (BCI): A Low-Delayed Asynchronous Wheelchair Control System," in *Neural Information Processing*. vol. 7663, T. Huang, *et al.*, Eds., ed: Springer Berlin Heidelberg, 2012, pp. 305-314.
- [47] T. W. Picton, "The P300 wave of the human event-related potential," *Journal of clinical neurophysiology*, vol. 9, pp. 456-479, 1992.
- [48] J. Polich, *et al.*, "P300 assessment of early Alzheimer's disease," *Electroencephalography and Clinical Neurophysiology/Evoked Potentials Section*, vol. 77, pp. 179-189, 1990.
- [49] K. C. Squires, *et al.*, "On the influence of task relevance and stimulus probability on event-related-potential components," *Electroencephalography and clinical neurophysiology*, vol. 42, pp. 1-14, 1977.
- [50] M. Kutas and S. A. Hillyard, "Event-related brain potentials to semantically inappropriate and surprisingly large words," *Biological psychology*, vol. 11, pp. 99-116, 1980.
- [51] Z. Leonowicz, *et al.*, "Trimmed estimators for robust averaging of event-related potentials," *Journal of neuroscience methods*, vol. 142, pp. 17-26, 2005.
- [52] A. Taboada-Crispí, *et al.*, "An adaptive enhancer with modified signal averaging scheme to detect ventricular late potentials," in *Progress in Pattern Recognition, Speech and Image Analysis*, ed: Springer, 2003, pp. 334-341.
- [53] A. C. N. Society, "Guideline 9B: guidelines on visual evoked potentials," *American journal of electroneurodiagnostic technology*, vol. 46, p. 254, 2006.

- [54] A. C. N. Society, "Guideline 9C: Guidelines on short-latency auditory evoked potentials," *Journal of clinical neurophysiology: official publication of the American Electroencephalographic Society*, vol. 23, p. 157, 2006.
- [55] C. P. Alejandro Herrera, Ruben Acevedo, "Estimación De Potenciales Evocados Auditivos Mediante Transformada Wavelet Y Descomposición Modal Empírica. Un Estudio Comparativo," *Scientia et Technica*, 2008.
- [56] R. Q. Quiroga, "Obtaining single stimulus evoked potentials with wavelet denoising," *Physica D: Nonlinear Phenomena*, vol. 145, pp. 278-292, 2000.
- [57] A. Grossmann and J. Morlet, "Decomposition of Hardy functions into square integrable wavelets of constant shape," *SIAM journal on mathematical analysis*, vol. 15, pp. 723-736, 1984.
- [58] S. A. Markazi, *et al.*, "Wavelet filtering of the P300 component in event-related potentials," in *Engineering in Medicine and Biology Society, 2006. EMBS'06. 28th Annual International Conference of the IEEE*, 2006, pp. 1719-1722.
- [59] S. Qian, *Introduction to time-frequency and wavelet transforms*: Prentice Hall, 2002.
- [60] I. Daubechies, *Ten lectures on wavelets* vol. 61: SIAM, 1992.
- [61] T. Demiralp, *et al.*, "Analysis of functional components of P300 by wavelet transform," in *Engineering in Medicine and Biology Society, 1998. Proceedings of the 20th Annual International Conference of the IEEE*, 1998, pp. 1992-1995.
- [62] E. W. S. Dean J. Krusienski, François Cabestaing, Sabri Bayouduh, Dennis J. McFarland, Theresa M. Vaughan and Jonathan R. and J. R. Wolpaw, "A Comparison of Classification Techniques for the P300 Speller," *Neural Engineering*, vol. 3, pp. 299-305, 2010.
- [63] M. O. Monteagudo, "Construcción y entrenamiento de Redes Neuronales Multicapa mediante el uso de Algoritmos Genéticos Celulares " Master en Ciencia de la Computación, Facultad de Matemática, Física y Computación Universidad Central "Marta Abreu" de Las Villas, Santa Clara, Cuba, 2006.
- [64] F. d. M. A. V. Herrero and S. V. G. Bote, "La aplicación de Redes Neuronales Artificiales (RNA): a la recuperación de la información," 1998.
- [65] J. CEVALLOS AMPUERO, "Aplicación de redes neuronales para optimizar problemas multirespuesta en mejora de la calidad," *Ind. data*, vol. 7, pp. 31-34, 2004.
- [66] K. Crowley, *et al.*, "Evaluating a Brain-Computer Interface to Categorise Human Emotional Response," in *ICALT*, 2010, pp. 276-278.
- [67] V. Peterson, *et al.*, "Detección de potenciales evocados relacionados a eventos en interfaces cerebro-computadora mediante transformada wavelet (Detection of event-related potentials in brain-computer interfaces using the wavelet transform Detecção de potenciais evocados relaci," *Revista Ingeniería Biomédica*, vol. 7, 2014.

- 
- [68] Y. Figueredo Baez, *et al.*, "Optimización en la solución del problema inverso en geofísica usando el algoritmo de entrenamiento Supervisado de LeVenberg-Marquardt," *Earth Sciences Research Journal*; núm. 6 (2002); 66-69 *Earth Sciences Research Journal*; núm. 6 (2002); 66-69 2339-3459 1794-6190, 2002.
- [69] A. Labajo, Q. Martín, and J. Labajo, "Configuración experimental de un perceptron multicapa para la modelización del comportamiento de la variables climáticas," 2012

## ANEXOS

### Anexo I Valores RMS de la señal reconstruida con cuatro wavelet madres diferentes

	coif4	db6	rbior1.5	haar
P1_1	8.85796538	8.85409488	8.76973129	8.655754
P2_1	9.36393836	9.35600762	9.31572594	9.06338749
P3_1	10.0808122	9.99780366	9.58072541	9.46669196
P4_1	9.78738639	9.8120089	9.75471343	9.42311348
P5_1	9.32987571	9.15410622	9.20127853	9.07126724
P6_1	9.18826371	9.13096838	9.00628526	8.87918093
P7_1	9.45746184	9.50353576	9.73772036	9.0744507
P8_1	9.82113094	9.6614594	9.64681343	9.6323867
P9_1	1.73148492	1.84693137	3.16849575	2.91518884
P10_1	6.37519287	6.31779473	6.27796251	6.14377566
P11_1	9.93787033	9.79330075	9.93052257	9.71489429
P12_1	10.6566223	10.6208594	10.6348743	10.5032804
P1_2	8.6837653	8.63338438	8.61837588	7.96006383
P2_2	9.33397535	9.30548515	9.31440894	8.92716817
P3_2	10.1236845	10.058274	9.61970649	9.31200364
P4_2	9.71067868	9.70058901	9.82569995	9.30922332
P5_2	47.7065247	47.7113084	47.8176175	47.3196969
P6_2	9.33277627	9.29043386	9.2960494	9.3544555
P7_2	6.93826935	7.00058816	6.93356196	7.26220401
P8_2	7.38764305	7.43061967	7.60470083	7.1379593

---

P9_2	3.02773378	3.09424134	4.06030369	3.96972393
P10_2	6.34805305	6.27230169	6.38045317	5.76585956
P11_2	8.68313012	8.3383349	7.85273792	8.62034378
P12_1	10.0808122	9.99780366	9.58072541	9.46669196