

Técnicas para Detección y Estimación Eficiente de Potenciales Evocados

Acevedo, Rubén C.; Gentiletti, Gerardo G.; Aldonate, Julio A.; Atum, Yanina V.; Biurrun Manresa, José A.; Bonell, Claudia E.; Escobar, Sergio O.; Filomena, Eduardo; Mercuri, Carlos H.; Richard, Miguel A.

AUTORES: Facultad de Ingeniería, Universidad Nacional de Entre Ríos, (3100) Oro Verde, Entre Ríos, Argentina.

CONTACTO: racedo@ingenieria.uner.edu.ar

Resumen

Los *potenciales evocados* (PE) en sus distintas modalidades (auditivos, visuales y somatosensoriales), se han convertido actualmente en un estudio de diagnóstico de patologías del sistema nervioso casi rutinario. Estos son señales eléctricas registradas mediante electrodos en el cuero cabelludo, que se producen como respuesta de los sistemas sensoriales a la aplicación de un estímulo adecuado. Sin embargo en su adquisición, además de la respuesta evocada por el estímulo, se registran potenciales generados por diversas fuentes fisiológicas y no fisiológicas; obteniéndose una *relación señal a ruido* (RSR) muy desfavorable que puede llegar a -20 dB en el caso de los potenciales *evocados auditivos de tronco cerebral* (PEATC).

La técnica comúnmente utilizada para mejorar la RSR, y estimar la señal de PE, es la promediación coherente o sincronizada; la cual consiste en aplicar sucesivos estímulos y promediar la actividad eléctrica registrada en forma sincronizada con el instante de tiempo en que se aplica el estímulo. Si bien la promediación es de uso masivo, presenta limitaciones que justifican buscar alternativas a esta. Una es el tiempo requerido para lograr una estimación confiable del PE, que dependiendo de la modalidad del mismo puede insumir más o menos tiempo; en el caso de los PEATC puede ser de hasta 5 minutos. Otra es que se asume que la señal de PE se mantiene constante de época a época y que el ruido (el resto de los potenciales) es del tipo blanco con media cero, hipótesis que no es cierta para la mayoría de los casos. En consecuencia el resultado obtenido de la promediación es una mala estimación de la señal real de PE. Asimismo, hay situaciones en las que no se necesita estimar la morfología de la señal y solo basta con saber si la señal está presente, como por ejemplo la detección automática de hipoacusias.

En este proyecto se propuso revisar, evaluar y desarrollar técnicas y/o algoritmos que permitan detectar la señal de PE así como también estimar de manera más eficiente que la promediación coherente.

Palabras clave: estimación, detección, potenciales evocados multimodales, potenciales relacionados a eventos, potenciales de estado estacionario, promediación coherente, reconocimiento de patrones

Estado actual del conocimiento del tema

Los potenciales evocados son señales eléctricas que se producen como respuesta de los sistemas sensoriales a la aplicación de un estímulo adecuado. Según sea la naturaleza del estímulo se producirá la respuesta del sistema sensorial correspondiente, y en función de esto será la modalidad del potencial evocado que se produzca: auditivo, visual o somatosensorial. Es posible utilizar diferentes patrones de estimulación, ubicación de electrodos y ventanas de análisis del registro, obteniéndose señales con distintos tipos de información relativa a las vías nerviosas involucradas [1].

Mediante electrodos aplicados en el cuero cabelludo, se pueden registrar cambios en los potenciales eléctricos asociados con la actividad evocada por la estimulación. Sin embargo, los PE están inmersos en una suma de otros potenciales generados por diversas fuentes fisiológicas tales como el electroencefalograma (EEG), el electromiograma (EMG), el electrocardiograma (ECG); y no fisiológicas como el ruido inducido por tensión de 50 Hz, señales de radio y ruido de instrumentación entre otros. El caso más desfavorable se presenta con los potenciales evocados auditivos de tronco cerebral, cuya amplitud máxima es del orden de los 0,2 a 1 μV , mientras que la amplitud del ruido es casi dos órdenes de magnitud mayor (alrededor de 50 μV), lo cual hace imposible percibir la señal de PE. Si bien el registro se hace en configuración diferencial para mejorar la relación señal ruido (RSR), esto no es suficiente, en parte inicialmente porque esta es muy pobre y en parte porque los espectros de frecuencias de la señal y del ruido están superpuestos, por lo cual tampoco es posible eliminar el ruido mediante un proceso de filtrado convencional [2].

En este contexto, si se denomina actividad al potencial registrado, señal al PE y ruido a los potenciales restantes; entonces para un instante de tiempo dado, la actividad en cualquier punto de la cabeza se considera como la suma algebraica de la señal y el ruido. Además se asume que estas son independientes una de otra, es decir, que la presencia de la señal no tiene efecto sobre el ruido [3].

Este modelo se cumple bastante bien para el caso de los PEATC pero no necesariamente en el resto de los potenciales evocados [4]. Si se indica el k -ésimo registro (o época) de la actividad como $x_k[n]$, a la señal de PE como $s[n]$ y a la k -ésima señal de ruido con varianza σ^2 como $r_k[n]$; entonces $x_k[n]$ puede expresarse como

$$x_k[n] = s[n] + r_k[n]$$

El proceso de promediación se expresa entonces como sigue:

$$y_N[n] = \frac{1}{N} \cdot \sum_{k=1}^N x_k[n] = s[n] + \frac{1}{N} \cdot \sum_{k=1}^N r_k[n]$$

donde N es el total de épocas promediadas.

El término de ruido puede ser interpretado, para cada instante n posterior al estímulo, como un estimador del valor medio de una muestra de N datos. Tal promedio resulta en una nueva variable aleatoria que tiene el mismo valor medio y una varianza igual a $\frac{\sigma^2}{N}$ [4]. Por lo tanto, la promediación produce una reducción de la varianza del ruido proporcional a N , mientras que mantiene constante la amplitud de la señal deseada $s[n]$; en consecuencia la RSR se ve mejorada en un factor de \sqrt{N} . De esta forma se puede mejorar la RSR promediando sucesivas épocas sincronizadas con el instante de aplicación de cada uno de los estímulos. Este método es conocido como promediación coherente

o sincronizada. En la figura 4 se muestra la promediación de 1, 100 y 900 épocas de un registro del PEATC, las gráficas tienen distintas escalas de amplitudes para una mejor observación del efecto [4].




FIGURA 4. Estimación de PEATC mediante promediación coherente.

a) 1 época (sin promediar), b) promedio de 100 épocas, c) promedio de 900 épocas.

Debe notarse sin embargo, que si bien la promediación coherente como técnica para mejorar la RSR es ampliamente aceptada, presenta ciertas limitaciones. La más importante es que se supone que la señal de PE se repite exactamente igual en cada época, lo cual no es cierto en la mayoría de los casos [5]. En consecuencia el proceso de promediación termina distorsionando la señal de interés.

En el caso de diagnóstico de patologías neurológicas, otra limitación a considerar es el tiempo necesario para obtener una estimación de la señal; lo cual se hace evidente en los PEATC. En este caso, la RSR inicial puede llegar a ser de -26 dB (1:20) y para obtener una morfología clara y definida de la señal de PEATC la RSR debe acercarse a un valor mínimo de 6 dB (2:1). Para lograr esa RSR es necesario promediar alrededor de 1600 épocas, y suponiendo una frecuencia de presentación de estímulos habitual de 11,11 estímulos por segundo, este proceso insume alrededor de 2.5 minutos; Además, para confirmar la morfología de la señal se deben realizar dos registros para verificar la replicabilidad de la señal de potencial evocado, por lo cual el tiempo necesario al menos se duplica, lo cual es un lapso prolongado para algunos estudios. Además, este tiempo es variable, ya que depende en cada caso de la amplitud de la respuesta del tronco cerebral, del ruido presente en el registro y de la colaboración de la persona [4].

En consecuencia, es importante explorar alternativas a la promediación coherente que disminuyan el tiempo requerido para la obtención de un trazo confiable de la señal de PE. En este sentido Sita *et al.* utilizaron filtrado no lineal basado en wavelets para mejorar la RSR de potenciales evocados auditivos de latencia media [6]. Turner *et al.* propuso combinar wavelets y algoritmos evolutivos como procesamiento para disminuir la cantidad de épocas a promediar [7]. Otras alternativas exploradas son variaciones de la promediación coherente, por ejemplo promediación pesada dato dependiente [8], métodos que utilizan información estadística del electroencefalograma y de los potenciales evocados [9], utilización de frecuencia alta de presentación de estímulos [10] y métodos de subespacios [11]. Un paso más adelante, y de aplicación para el caso de potenciales evocados de mayores amplitudes como los visuales, somatosensoriales o auditivos de latencias media y larga; hay autores que proponen métodos para estimar la señal con una sola realización. Algunas alternativas exploradas para algunas aplicaciones son denoising con wavelets [12], filtrado Kalman [13], análisis de componentes independientes (ICA) [14] y uso de descomposición empírica de modos [15].

Por otro lado, hay situaciones en las que no se necesita estimar la morfología de la señal y solo basta con saber si está presente, o no, la señal de potencial evocado. Este es el caso de detección automática de hipoacusias o el de aplicaciones que en los últimos años ha cobrado un gran interés, las denominada Interfaces Cerebro-Computadoras (BCI del inglés Brain-Computers Interfaces) basadas en el paradigma de Potenciales evocados Relacionados a Eventos (ERP, del inglés Event Related Potentials) [16] o de Potenciales Visuales de Estado Estacionario (SSVEP, del inglés Steady State Visual Evoked Potentials).

En la detección automática de hipoacusias los factores claves son el de cometer el mínimo error posible en la detección de la respuesta, generalmente medido en términos de sensibilidad y especificidad del método, y el tiempo empleado en realizar la misma. Ambos factores son particularmente importantes cuando se habla de detección de hipoacusias en neonatos; ya que afectan directamente el costo, y por ende la factibilidad, de creación programas de exploración universal sobre grandes poblaciones de niños [17]-[20]. En el caso de las BCI los algoritmos de detección, o de forma más general de "clasificación", tienen un rol determinante en el desempeño de las mismas. En particular, en varios de los paradigmas utilizados en el ámbito de las BCI, entre ellos los ERP y SSVEP, la problemática está altamente correlacionada con la de detección automática de hipoacusias mediante PEATC. En ambos se repite la situación de la necesidad de detectar respuestas evocadas o moduladas por el sujeto, que están inmersas en actividad eléctrica descorrelacionada y considerada como ruido. También en este caso, la disminución de la cantidad de épocas necesarias para realizar determinar la presencia o ausencia de las respuestas, es de vital importancia. Esto incide directamente en la tasa de transferencia de información que se logrará entre el sujeto y la computadora, a menos épocas requeridas, se tendrán decisiones más rápidas y con ellas más información o comandos enviados y con menor error.

Metodología

La presente propuesta consistió en el desarrollo y evaluación de algoritmos para estimar y/o detectar eficientemente señales de potenciales evocados.

Se realizaron registros en el Laboratorio de Ingeniería en Rehabilitación e Investigaciones Neuromusculares y Sensoriales (LIRINS) de la FIUNER, utilizando la infraestructura disponible (gorra Electro Cap de 34 canales, 16 amplificadores Grass modelo 8-18-36, 2 placas de adquisición A/D Data Translation modelo DT9816, software de adquisición BCI2000, estimuladores auditivo y visual desarrollado en el LIRINS).

Resultados alcanzados

En esta sección se presentan los resultados más importantes obtenidos a lo largo del desarrollo del proyecto.

1.a Base de datos para pruebas de algoritmos desarrollados

En la actualidad, el desarrollo de nuevas tecnologías en la industria médica y la investigación aplicada en el área de la bioingeniería se sustenta en gran parte en el desarrollo de nuevos algoritmos de procesamiento de señales. La evaluación del desempeño de estos algoritmos debe incluir la validación de los resultados que se obtienen a partir del análisis y procesamiento que se haga sobre la señal

registrada (señales electrofisiológicas o imágenes médicas) y la evaluación de su robustez ante diferentes condiciones de registro de la señal. Esta validación es un requisito fundamental establecido por las regulaciones y normas nacionales e internacionales para productos médicos. Esta etapa es la más difícil, fundamentalmente debido a que las señales con las cuales trabajan estos algoritmos tienen una variabilidad alta entre sujetos e, inclusive, en el mismo sujeto en distintas instancias de registro. Además las características propias de las señales dependen de las condiciones en las cuales han sido registradas y requieren muchas veces de la utilización de estrategias de normalización. La validación de los resultados obtenidos debe incluir la utilización de las herramientas estadísticas adecuadas para la evaluación de la consistencia de los resultados obtenidos. Por esto, muchas de las aplicaciones clínicas de los algoritmos fuera del ámbito de la investigación son limitadas. Por esto, se desarrolló la programación de una base de datos de señales electrofisiológicas basadas en Internet. Para su desarrollo se utilizaron herramientas de software libre. El motor de la base de datos utilizada es el MySQL, el cual posee licencia de uso gratuita, permite el manejo de volúmenes de información medianamente grandes, cuenta con medidas de seguridad que permiten la administración de privilegios para el acceso a la información por parte de las distintas clases de usuarios y el respaldo de la información, permite alojar la base de datos en cualquier plataforma (Windows, Linux, etc.), y contiene mecanismos de back up que facilitan el respaldo y restauración de la información alojada.

El sistema de gestión de la base de datos implementado comprende tres módulos: un módulo de carga de nuevas señales, otro de autorización y verificación de carga de las mismas y un tercero para la consulta y acceso a las señales contenidas en la base. El módulo de carga, accesible desde cualquier laboratorio de la FIUNER registrado como tal, permite ingresar nuevas señales a la base. Estas deben ser ingresadas junto al protocolo de registro de la misma, y previa autorización por parte del administrador, son volcadas a la base de datos en forma definitiva. El usuario o usuarios que tengan la categoría de administrador tienen por función verificar los datos cargados, que los datos contenidos en el protocolo sean los necesarios para la correcta interpretación de la señal y que la señal cargada sea la correcta. Las señales que sean efectivamente incluidas en la base podrán ser consultadas a través de un módulo de consulta. En él todos los usuarios registrados pueden descargar el archivo comprimido de las señal/es cargada/s y visualizar los datos asociados a estas en forma de tabla.

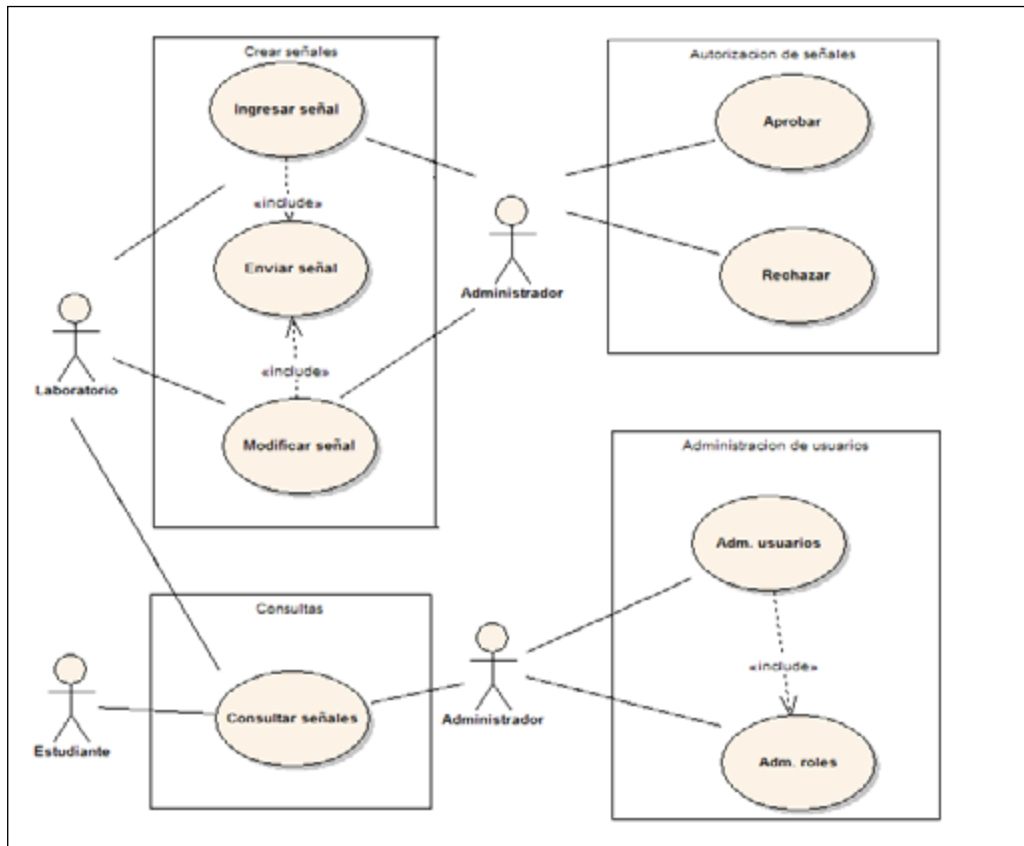


FIGURA 1. Actividades según el tipo de usuarios.

Las actividades reservadas para cada tipo de usuario y su relación con los módulos se representan en la Figura 1.

En la figura 2 se muestra el aspecto que muestra la base al ingreso como administrador en el menú de carga de señales. En esta instancia, el usuario de la base (administrador o laboratorio autorizado) debe ingresar los datos de la señal a almacenar: código de identificación de paciente, edad, protocolo, fecha de captura y señales registradas.

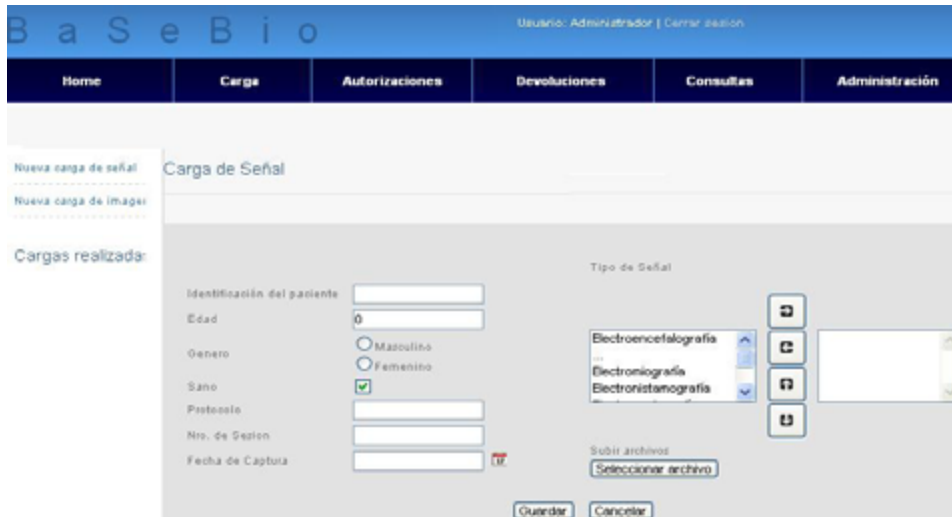


FIGURA 2. Pantalla de carga.

En la figura 3 se muestra el aspecto que muestra la base en el menú de consulta. La búsqueda se puede realizar por señales o bien, por el nombre o código del protocolo o paciente, fecha de captura, número de sesión o laboratorio que generó la señal.



FIGURA 3. Pantalla de consultas.

1.b Desarrollo de algoritmos de estimación de potenciales evocados

Los potenciales evocados auditivos del tronco cerebral (PEATC) son frecuentemente usados para fines diagnósticos, sin embargo su procesamiento se hace difícil porque están inmersos en una gran cantidad de ruido proveniente no solo de fuentes externas sino también de otras fuentes fisiológicas. Hasta ahora el método más utilizado y aceptado para obtener un registro confiable es la promediación coherente, sin embargo este tipo de procesamiento presenta algunos inconvenientes.

La descomposición modal empírica (EMD) es una técnica relativamente nueva que se usa para el procesamiento de señales no estacionarias como la mayoría de señales fisiológicas. Esta separa una secuencia de datos en una suma de componentes (IMFs) y cada uno de estos contiene diferentes modos oscilatorios. Las funciones base o IMFs son derivadas directamente de la misma señal y solo se requiere que la señal tenga mínimo dos extremos, un máximo y un mínimo [21]

La descomposición se hace de acuerdo a los lapsos de tiempo entre los mínimos y máximos locales; y los cruces consecutivos por cero. Así, una señal debe cumplir dos condiciones para ser un IMF: a)

el número de extremos y el número de cruces por cero deben ser iguales o diferentes por uno y b) en cualquier punto, el valor de la media de los envolventes definidos por los máximos y mínimos locales debe ser cero. Por ejemplo, dada una señal $X(t)$ que es la suma de dos señales, una modulada en amplitud y otra senoidal, el proceso de descomposición modal consiste en:

a) Identificar los mínimos y máximos locales e interpolar por medio de funciones splines cúbicas, así se obtiene una envolvente superior $e_{\text{sup}}(t)$ y otra inferior $e_{\text{inf}}(t)$. Estas dos envolventes deben contener todos los datos entre sí.

b) La media entre estas dos envolventes es designada como:

$$m_1(t) = \frac{e_{\text{sup}}(t) + e_{\text{inf}}(t)}{2} \quad (2),$$

y luego se halla el residuo entre la señal original y la media $x(t) - m_1(t) = h_1(t)$ (3)

Lo ideal es que h_1 fuera un IMF, pero antes debe cumplir las condiciones ya mencionadas, así que se sigue iterando. En la segunda iteración, h_1 es tomada como la señal ($h_1 - m_{11} = h_{11}$) y este procedimiento se puede realizar k veces ($h_{1(k-1)} - m_{1k} = h_{1k}$) hasta obtener un IMF $c_1 = h_{1k}$.

c) El residuo entre los datos iniciales y el IMF resultante,

$$r(t) = X(t) - h_{1k}(t) \quad (4)$$

es tratado como una nueva señal para seguir haciendo el proceso y hallar otro IMF.

Este algoritmo continúa hasta que el residuo se hace muy pequeño y no tiene puntos de inflexión. Al final del proceso la señal puede ser expresada de la siguiente manera:

$$x(t) = \sum_{i=1}^k c_i(t) + r_k(t) \quad (5)$$

donde $c_i(t)$ son los diferentes IMFs, k es el número total de IMFs y $r_k(t)$ es el residuo final. Los IMFs son casi ortogonales entre sí y tienen media cero, por lo tanto, cada IMF contiene un ancho de banda en frecuencia y amplitud de la señal original [21], [22].

En la investigación se evaluó la EMD como una herramienta para mejorar el desempeño de la promediación coherente de PEATC buscando reducir la cantidad de épocas necesarias para obtener un registro confiable. Para tal fin se analizó la reconstrucción de ocho registros usando solamente los modos 2, 3 y 4 resultantes de la EMD, los estudios determinaron que una reconstrucción de 800 épocas es aceptable. Más detalle se puede encontrar en [23].




FIGURA 4. En línea continua se muestra un registro de PEATC de 2000 épocas y en la línea discontinua una reconstrucción con los IMFs 2, 3 y 4 después de realizar la descomposición modal a un registro de PEATC de 800 épocas.

1.c Desarrollo de algoritmos de detección de potenciales evocados

Una interfaz cerebro computadora es un sistema que genera una forma de comunicación artificial entre el cerebro de una persona y el mundo exterior, uno de los paradigmas más utilizados es el basado en potenciales evocados relacionados a eventos (PRE). Como objetivo se planteó resolver en forma eficiente el problema de detección de la señal de PRE convirtiéndolo en un problema de clasificación con dos clases posibles: registros con respuesta y registros sin respuesta.



FIGURA 5. Arquitectura general de una ICC para control de dispositivos

Como clasificador se utilizaron máquinas de soporte vectorial lineales y perceptrones simples, y se recurrió a un esquema de extracción de características basado en algoritmos genéticos en combinación con máquinas de soporte vectorial (en configuración envolvente o wrapper). Más detalles de este trabajo se pueden encontrar en [24] y [25].

Para evaluar el desempeño de las diferentes configuraciones se calcularon el porcentaje de aciertos, la sensibilidad y especificidad, para las distintas cantidades de épocas utilizadas. La configuración envolvente mostró un significativo aumento en estos índices, aun cuando utiliza menos de un 50 % de las características del patrón temporal real y aproximadamente un 20% de las características de los patrones simulados.

TABLA I. RESULTADOS OBTENIDOS

Épocas	AG + PSC			AG + MSV		
	% aciertos	Sens.	Esp.	% aciertos	Sens.	Esp.
20	92.5	0.95	0.90	92.0	0.92	0.92
15	90.3	0.92	0.88	88.4	0.88	0.88
10	87.5	0.92	0.82	89.0	0.82	0.96
9	84.1	0.91	0.77	87.5	0.86	0.88
8	84.0	0.90	0.78	89.0	0.82	0.96
7	80.7	0.86	0.75	86.8	0.84	0.89
6	79.5	0.84	0.74	88.0	0.82	0.94
5	78.1	0.91	0.65	89.0	0.92	0.86
4	75.5	0.89	0.62	88.1	0.82	0.94
3	71.5	0.78	0.55	89.1	0.94	0.84
2	66.0	0.72	0.60	88.1	0.86	0.90
1	65.0	0.68	0.62	87.0	0.82	0.92

Sens.: sensibilidad. Esp.: especificidad.

Además se abordó el problema de detección de señales de PRE realizando la extracción de características mediante métodos de aproximación de señales basados en diccionarios, en particular generándolo mediante transformada wavelet diádica discreta.

Hay diversas alternativas, algunas son más adecuadas que otras en función de la señal y de las características que se quieran resaltar. En este proyecto se utilizó un método de aproximación basados en diccionarios, en este contexto la señal de interés se considera como un elemento de un espacio de señales que puede representarse en función de una base que favorezca la expresión de las características buscadas. En este contexto se puede expresar la señal $\mathbf{x} \in \mathbb{R}^N$ en función de una base ortogonal mediante la ecuación $\mathbf{a} = \phi \cdot \mathbf{x}$ donde $\mathbf{a} \in \mathbb{R}^N$ es el vector expresado en la nueva base y ϕ es una matriz $\in \mathbb{R}^{N \times N}$ cuyas columnas son los elementos de la nueva base denominados átomos [27].

La matriz ϕ se construyó mediante la descomposición multiresolución producido por la transformada wavelet diádica discreta (DDWT, diadic discret wavelet transform) utilizando la wavelet Biorthogonal 3.9, la cual se seleccionó por su parecido morfológico con el pico P300. En la figura 6 se muestra la descomposición hasta el nivel 5, en cada nivel la señal se separa en una porción de altas frecuencias llamada *detalle* y en otra de bajas frecuencias llamada *aproximación*; la descomposición en el nivel posterior se realiza sobre esta última. En la figura 6 el *i*-ésimo detalle se representa como D_i , mientras que la *i*-ésima aproximación como A_i .




FIGURA 6. Descomposición multiresolución de ERP.

Este proceso también puede verse como la aplicación de filtros pasa bajos y pasa altos sucesivas veces; donde en cada nivel además hay un proceso de decimación por 2 de la señal [27]. Siguiendo este razonamiento, y considerando que la señal de ERP original tiene 1024 muestras, la *aproximación* y *detalle* en el nivel 5 tienen 32 muestras cada una. Debido a que el ancho de banda de los ERP es menor a 10Hz, entonces toda la información se encuentra en la aproximación del nivel 5 (A5). Por lo tanto, aplicando la descomposición multiresolución sobre el promedio de M épocas (patrón temporal de 1024 muestras) se obtiene un nuevo patrón de 32 muestras.

El clasificador utilizado fue un perceptron de simple capa. Se compararon los resultados obtenidos en la detección de los ERP para los casos de patrones temporales y patrones wavelets. Los resultados obtenidos se muestran en la Tabla II, son muy buenos en el caso de señales simuladas, no siendo así para el caso de registros reales.

TABLA II. RESULTADOS OBTENIDOS

Épocas	Temporales		Wavelets	
	Sens.	Espec.	Sens.	Espec.
20	0.9	0.65	0.85	0.70
10	0.85	0.60	0.85	0.60
9	0.81	0.86	0.77	0.66
8	0.83	0.64	0.85	0.60
7	0.84	0.60	0.84	0.57
6	0.78	0.57	0.78	0.60
5	0.77	0.62	0.82	0.62
4	0.81	0.58	0.77	0.56
3	0.78	0.57	0.77	0.59
2	0.72	0.56	0.72	0.56

Se analizó el desempeño de un ensamble de tres clasificadores que utilizan el análisis discriminante lineal (ADL). El objetivo fue comparar el desempeño del sistema basado en un ensamble contra el de un clasificador individual, de acuerdo a los algoritmos para la generación de los clasificadores individuales y los procedimientos a través de los cuales sus salidas pueden ser combinadas.

Se evaluaron las siguientes estrategias de construcción de ensambles:

- Bagging: es la abreviatura de bootstrap aggregating, que es uno de los primeros algoritmos basados en ensamble. El método obtiene la diversidad mediante el uso de réplicas bootstrap de los datos de entrenamiento. Para cada subconjunto de datos de entrenamiento se utiliza un clasificador diferente del mismo tipo. Clasificadores individuales se combinan, a través de una votación de mayoría de sus decisiones. Para un caso dado, la clase elegida por la mayoría de los clasificadores es la decisión de conjunto.
- Boosting: crea un conjunto de clasificadores por remuestreo de los datos, éste se orienta estratégicamente a brindar un conjunto de entrenamiento más informativo para cada clasificador consecutivo. En esencia, crea tres clasificadores débiles: el primer clasificador (C1) se entrena con un subconjunto aleatorio de los datos de entrenamiento disponibles. El subconjunto de datos de entrenamiento para el segundo clasificador (C2) es elegido como el subconjunto más informativo, dado C1. Es decir, C2 está entrenado con una base de datos de entrenamiento donde sólo la mitad de los patrones se han clasificado correctamente por C1. El tercer clasificador (C3) se entrena con

los patrones en los que no están de acuerdo C1 y C2. Los tres clasificadores se combinan a través de una mayoría de votación.

- K-means: es una estrategia de selección alternativa de los grupos de entrenamiento, donde se separa el conjunto de patrones de entrenamiento en un número determinado subconjuntos, procurando tener una distribución particular para cada clasificador teniendo, de esta manera, clasificadores expertos en un determinada área local del espacio total de características.

A partir de los métodos descritos anteriormente se evaluaron distintas alternativas de combinar las salidas de los clasificadores que conforman los ensambles:

- Votación simple: se realiza un conteo de la cantidad de votos recibidos por cada clase por parte de cada clasificador y la clase seleccionada por el conjunto es la de mayor cantidad de votos.
- Votación ponderada: cada clasificador recibe un determinado peso en la votación final en función de su desempeño durante el proceso de entrenamiento.
- Regla del mínimo/máximo/mediana: Como el nombre lo indica, son funciones simplemente para tomar la mínima, máxima o mediana entre las salidas continuas de los clasificadores individuales.
- Regla del producto: se multiplican los valores continuos de salidas de cada clasificador, esta regla es muy sensible a los clasificadores más pesimistas
- Regla de la media: el apoyo a la clase j se obtiene como la media de todas las salidas continuas de los clasificadores. Ésta es equivalente a la regla de la suma por un factor de normalización $1/T$, siendo T la cantidad de clasificadores.
- BKS: construido sobre la base de la clasificación de los datos de entrenamiento que realiza un seguimiento de la frecuencia con cada combinación de etiquetado producida por los clasificadores.
- Entonces, la clase verdadera, se obtiene mediante una combinación particular de etiquetado en función de la frecuencia de ocurrencia, y ésta es elegida cada vez que la combinación de etiquetas de clase ocurra durante el testeo.

Los resultados obtenidos se muestran en la figura 7, los cuales se obtuvieron utilizando el *área bajo la curva* (AUC, del inglés Area Under Curve) se pudo concluir que para esta aplicación sobre ICC, y el tipo de clasificador usado, el clasificador individual posee un mayor desempeño que los ensamble propuestos.




FIGURA 1. AUC en función del método de combinación de salidas de los clasificadores para el individuo N°1, donde en el eje de las abscisas se representa las distintas combinaciones de salida: votación simple (vot. s.), votación ponderada (vot. pond.), regla del producto (R. Prod.), Regla de la suma (R. Suma), Regla de la suma ponderada (R. S. Pond.), Regla del máximo (R. Max.), Regla del mínimo (R. Min.), Regla de la media (R. Media).

Conclusiones

En el presente trabajo se evaluaron distintas alternativas para implementar algoritmos de estimación y detección de potenciales evocados. En el caso de estimación de potenciales evocados auditivos de troco cerebral se evaluó la descomposición modal empírica, que si bien es necesario mejorarla presenta buenas perspectivas para su aplicación.

La mayor parte de la investigación se desarrolló en la evaluación de estrategias para detección de potenciales evocados visuales en el marco de interfaces cerebro computadoras. En este contexto se abordaron estrategias para generación de características mediante transformación ortogonales (por ejemplo wavelets) en combinación con distintas alternativas de clasificación.

Como trabajo futuro se propone profundizar la evaluación de estrategias que permitan generar características, ya sea mediante otras transformaciones ortogonales o bien mediante enfoques menos convencionales como por ejemplo representaciones ralas.

Bibliografía

- [1] *Spehlmann's Evoked Potentials: Primer Visual, Auditory and Somatosensory Evoked Potentials in Clinical Diagnosis*. K. Misulis. Butterworth-Heinemann, 1994.
- [2] *Electroencephalography: basic principles, clinical applications and related fields*. E. Niedermeyer, F. Lopes da Silva. 5ta. ed., Lippincott Williams & Wilkins, 2005.
- [3] *Current Practice of Clinical Electroencephalography*. D. Daly, T. Pedley. Lippincott-Raven, 1990.
- [4] *Potenciales evocados auditivos de tronco cerebral: Aspectos tecnológicos del registro*. Rubén Acevedo, Claudia Bonell, Gabriel Gentiletti, Julio Aldonate, Carlos Mercuri, Sergio Escobar, José Biurrun. Revista Argentina de Bioingeniería (SABI), Vol. 12 No. 1, Junio 2006, pp. 10-17.
- [5] *Evoked Potentials in Clinical Medicine*. K. Chiappa K. Lippincott-Raven, 3º ed., 1997.
- [6] *Wavelet Domain Nonlinear Filtering for Evoked Potential Signal Enhancement*. G. Sita and A. G. Ramakrishnan. Computers and Biomedical Research 33, 431–446 (2000).
- [7] *Extraction of short-latency evoked potentials using a combination of wavelets and evolutionary algorithms*. S. Turner, P. Picton, J. Campbell. Medical Engineering & Physics 25 (2003) 407–412.
- [8] *Weighted averaging of steady-state responses*. M. Sasha John, Andrew Dimitrijevic, Terence W. Picton. Clinical Neurophysiology 112 (2001) 555-562.
- [9] *A Bayesian approach to estimate evoked potentials*. Giovanni Sparacino a, Stefano Milani a,b, Edoardo Arslan b, Claudio Cobelli. Computer Methods and Programs in Biomedicine 68 (2002) 233–248.
- [10] *The use of QSD (q-sequence deconvolution) to recover superposed, transient evoked-responses*. Don L. Jewett, Gideon Caplovitz, Bill Baird, Michael Trumpis, Marram P. Olson, Linda J. Larson-Prior. Clinical Neurophysiology 115 (2004) 2754–2775.
- [11] *Subspace Regularization Method for the Single-Trial Estimation of Evoked Potentials*. Pasi A. Karjalainen, Jari P. Kaipio, Anu S. Koistinen, and Marko Vauhkonen. IEEE Trans. on Biomed. Eng., vol. 46, no. 7, July 1999.
- [12] *Single-trial event-related potentials with wavelet denoising*. R. Quiñ Quiroga, H. García. Clinical Neurophysiology 114 (2003) 376–390.
- [13] *Single-Trial Dynamical Estimation of Event-Related Potentials: A Kalman Filter-Based Approach*. Stefanos D. Georgiadis, Perttu O. Ranta-aho, Mika P. Tarvainen, and Pasi A. Karjalainen. IEEE Trans. on Biomed. Eng., vol. 52, no. 8, August 2005.

- [14] *Single-trial evoked potential estimation: Comparison between independent component analysis and wavelet denoising.* Darshan Iyer, George Zouridakis. *Clinical Neurophysiology* 118 (2007) 495–504.
- [15] *Single Trial P300 detection based on the Empirical Mode Decomposition.* Solis-Escalante T., Gentiletti G.G., Yáñez-Suárez O. *Proceeding of 28th IEEE–EMBS Annual International Conference.* New York City, New York, USA. (2006) 1157-1160.
- [16] *The mental prosthesis: Assessing the Speed of a P300-Based Brain–Computer Interface,* Donchin E, Spencer KM, Wijesinghe R. *IEEE Transactions on Rehabilitation Engineering*, 8:174–179 2000.
- [17] *Hearing screening in healthy newborns: feasibility of different methods with regard to test time.* M. Hahn, A. Lamprecht-Dinnesen, A. Heinecke, S. Hartmann, S. Bulbu, G. Schroder, J. Steinhard, F. Louwen, E. Seifert. *International Journal of Pediatric Otorhinolaryngology* 51 (1999) 83–89.
- [18] *A review of classification algorithms for EEG-based Brain–Computer Interfaces.* F Lotte, M Congedo, A L'ecuyer, F Lamarche, B Arnaldo J. *Neural Eng.* 4 (2007) R1–R13.
- [19] *A survey of signal processing algorithms in Brain–Computer Interfaces based on electrical brain signals,* Ali Bashashati, Mehrdad Fatourech, Rabab K Ward, Gary E Birch
- [20] *Universal screening for infant hearing impairment: simple, beneficial and presently justified.* K. White, A. Maxon. *International Journal of Pediatric Otorhinolaryngology* 32 (1995) 201–211.
- [21] *Empirical mode decomposition: a method for analyzing neural data.* *Neurocomputing* Liang H., Bressler S., Desimone R., Fries P., 65-66, 801-807, 2005.
- [22] *The empirical mode decomposition and Hilbert spectrum for nonlinear and nonstationary time series analysis* N.E. Huang, Z. Shen, S.R. Long, M.L. Wu, H.H. Shih, Q. Zheng, N.C. Yen, C.C. Tung and H.H. Liu, , *Proc. Roy. Soc. London A, Vol. 454, pp. 903–995, 1998.*
- [23] *Estimación de potenciales evocados auditivos del tronco cerebral mediante descomposición modal empírica.* Carolina Posada Zuluaga, Rubén Acevedo, , *Revista Ingeniería Biomédica (EIA, Colombia)*, Vol. 2, No. 3, pp. 27-32, Junio 2008, ISSN 1909–9762.
- [24] *Detección de P300 en Interfaz Cerebro Computadora mediante Algoritmos Genéticos y Máquinas de Soporte Vectorial* Yanina Atum, Gerardo G. Gentiletti, Rubén Acevedo, Leonardo Rufiner, XVII Congreso Argentino de Bioingeniería, Rosario, Octubre de 2009.
- [25], *“Detección de Potenciales Evocados en Interfaces Cerebro Computadora mediante Técnicas de Aprendizaje Maquinal”*, Yanina Atum, Gerardo G. Gentiletti, Rubén Acevedo, II Jornadas Chilenas de Ingeniería Biomédica, Viña del Mar (Chile), Octubre de 2009.
- [26] *“Extracción de características en ICC mediante métodos basados en diccionarios óptimos: Resultados preliminares”*, Rubén Acevedo, Gerardo Gentiletti, Verónica Medina Bañuelos, Leonardo Rufiner, II Jornadas Argentinas sobre Interfaces Cerebro Computadora, pags. 49-52, Abril 2009.
- [27] *“Análisis y representación de la voz mediante técnicas no convencionales”*, Rufiner H. L., Tesis de Doctorado en Ingeniería, Universidad de Buenos Aires, Argentina, 2005.

PID 6101 Denominación del Proyecto

Técnicas para detección y estimación eficiente de potenciales evocados

Directora del proyecto

ACEVEDO, Rubén

Codirector

GENTILETTI, Gerardo G.

Unidad Ejecutora

Facultad de Ingeniería (UNER)

Dependencia

Universidad Nacional de Entre Ríos

Contacto

racedo@ingenieria.uner.edu.ar

Integrantes del Proyecto

ALDONATE, Julio A.; ATUM, Yanina V.; BIURRUN MANRESA, José A.;
BONELL, Claudia E.; ESCOBAR, Sergio O.; FILOMENA, Eduardo;
MERCURI, Carlos H.; RICHARD, Miguel A.

Fechas de iniciación y de finalización efectivas

24/09/2008 y 24/09/2012

Aprobación del Informe Final por Resolución CS N°374/17 (01/11/2017)

[«« VOLVER AL INICIO](#)