



Procesamiento de señales cerebrales provenientes de estímulos visuales y auditivos utilizando análisis wavelet y redes neuronales artificiales

Processing of brain signals from visual and auditory stimuli using wavelet analysis and artificial neural networks

Alberto Lizcano-Portilla ¹, Luis Mendoza ², Zulmary Nieto-Sánchez ³

¹ Grupo de investigación de Ingeniería Biomédica (Gibup), Ingeniería Electrónica, Universidad de Pamplona, Colombia. Orcid: 0000-0003-4006-874X. Correo electrónico: alberto7526@gmail.com

² Grupo de investigación de Ingeniería Biomédica (Gibup), Ingeniería en Telecomunicaciones, Universidad de Pamplona, Colombia Orcid: 0000-0002-2012-9448. Correo electrónico: luis.mendoza@unipamplona.edu.co

³ Grupo de investigación EULER, Universidad Francisco de Paula Santander Colombia. Orcid: 0000-0001-6725-4601. Correo electrónico: zulmarycarolinanisa@ufps.edu.co

Recibido: 14 octubre, 2019. Aceptado: 20 enero, 2020. Versión final: 20 marzo, 2020.

Resumen

Este artículo presenta el diseño y desarrollo de un prototipo portátil para la adquisición, procesamiento y clasificación de señales EEG con el objetivo de caracterizar estímulos visuales y auditivos, se trabajó con dos pacientes diferentes para la validación de los resultados, se realizó el registro de las señales durante 4 segundos a una frecuencia de 500Hz. Los pacientes fueron expuestos a estímulos visuales y auditivos en diferentes casos, cuya frecuencia de aparición permanecía constante. Para el registro de las señales se diseñó un sistema de adquisición de 4 canales configurables entre sí para trabajar con derivación unipolar o bipolar según requiera el experimento. La selección de la mejor base en el análisis multi-resolución de wavelet se tuvieron en cuenta dos parámetros importantes, la medida de la entropía y los porcentajes de clasificación de dichos niveles, debido a que los potenciales evocados son generalmente constantes en su morfología, se hizo promediación coherente dando como resultado la ubicación espacio-tiempo donde aparece dicho potencial evocado, una vez se obtuvo las características de la señal tratada se procedió a clasificarlas mediante dos métodos diferentes de inteligencia artificial, redes neuronales y máquinas de soporte vectorial, en esta etapa se tomó en cuenta la medida de la desviación estándar de los datos, para garantizar que la máquina de aprendizaje se entrene de manera correcta. Los resultados obtenidos demuestran de manera fidedigna el comportamiento general de los potenciales evocados como resultado a los estímulos presentados, además de que se pudo comprobar la variación de las ondas alfa del paciente según su estado de relajación o alerta en cada caso, es recomendable realizar un sistema de filtrado mucho más robusto para aumentar la relación señal a ruido de la señal EEG, facilitar su análisis y mejorar los resultados.

Palabras clave: señal EEG; entropía; potencial evocado; análisis multi-resolución; inteligencia artificial.

Abstract

This article presents the design and development of a portable prototype for the acquisition, processing and classification of EEG signals with the aim of characterizing visual and auditory stimuli. Two different patients were worked with to validate the results, and the signals were recorded for 4 seconds at a frequency of 500Hz. The patients



were exposed to visual and auditory stimuli in different cases, whose frequency of appearance remained constant. For the recording of the signals, a 4-channel acquisition system was designed, which could be configured to work with unipolar or bipolar derivation, as required by the experiment. The selection of the best base in the multi-resolution wavelet analysis, two important parameters were taken into account, the measurement of entropy and the percentages of classification of these levels, because the evoked potentials are generally constant in their morphology, it was made coherent averaging giving as a result the space-time location where this evoked potential appears, Once the characteristics of the treated signal were obtained, they were classified using two different methods of artificial intelligence, neural networks and vector support machines. At this stage, the measurement of the standard deviation of the data was taken into account to ensure that the learning machine was trained correctly. The results obtained reliably demonstrate the general behaviour of the evoked potentials as a result of the stimuli presented. In addition, it was possible to verify the variation of the patient's alpha waves according to his or her state of relaxation or alert in each case, it is advisable to carry out a much more robust filtering system to increase the signal-to-noise ratio of the EEG signal, facilitate its analysis and improve the results.

Keywords: EEG signal; entropy; evoked potential; multi-resolution analysis; artificial intelligence.

1. Introducción

El avance en la tecnología, específicamente en el estudio del cerebro humano ha avanzado en gran medida durante los últimos años, las señales EEG, señales bioeléctricas relacionadas con la actividad eléctrica del cerebro, tienen parte importante para poder comprender como funciona el cerebro humano, al igual que posee muchas aplicaciones en la medicina y puede ayudar a la recuperación de gran número de pacientes que presenten algún tipo de discapacidad motriz, problemas de concentración entre otros. Problemas que anteriormente no existía una manera de tratarlos o disminuir sus efectos en los pacientes, particularmente los potenciales evocados, señales EEG que pueden ser provocadas mediante un estímulo externo ya sea visual, auditivo o somato sensorial, nos proporcionan esa herramienta de trabajo.

La importancia de esta investigación radica en el gran número de pacientes con diferentes problemáticas como las mencionada anteriormente, y la necesidad que esto provoca priorizando en los costos y su disponibilidad de desplazamiento, este trabajo ofrece una posible solución a esta problemática y genera un paso inicial para poder convertir un dispositivo que actualmente puede llegar hacer muy costoso en un dispositivo de fácil acceso para la población interesada, usando algunas técnicas de procesamiento digital de señales y de inteligencia artificial, sin embargo la construcción de estos dispositivos no puede ser del todo fácil, ya que existen muchos factores que intervienen en la fabricación de los mismos [1], se evidencian algunas metodologías para la construcción de estos dispositivos [2, 3], así como algunas precauciones a tener en cuenta en el proceso de fabricación y montaje de los componentes que intervienen en ello [4, 5].

Una de las problemáticas muy común es la baja relación señal a ruido que presentan los potenciales evocados en general [6], los dispositivos que fueron diseñados para este propósito cuentan con una etapa de filtrado generalmente analógico, digital o ambos, sin embargo existen algunos que presentan filtros un poco más elaborados con el propósito de eliminar artefactos presentes en la señal EEG que un filtro común no podría eliminar [7, 8], así como también extraer la mayor información posible de estas señales desechando lo sobrante, entre los que se destacan el método propuesto por los autores [9] implementado en este trabajo y otros métodos también utilizados con frecuencia para tratar este tipo de señales [10, 11], las posibles aplicaciones que tiene el estudio de señales EEG varían desde darle la capacidad a personas con discapacidad motriz de comunicarse [12] o recuperar cierto grado de autonomía [13] hasta evaluar nuevos métodos de aprendizaje o ayudar a la rehabilitación tanto psicológica como muscular en pacientes con problemas particulares [14, 15, 16], para hacer más aceptable el uso de estos dispositivos en la vida cotidiana el factor velocidad es un parámetro que también se ha tenido en cuenta para la construcción de estas interfaces [17], si deseamos saber un poco más acerca de la evolución de este tipo de dispositivos en los últimos años en [18] se presenta un estado del arte bastante completo hasta el año 2012.

El uso de técnicas de procesamiento de señales y técnicas de inteligencia artificial para tratar señales EEG, nos da la oportunidad de reducir costos en cuanto al diseño y fabricación de complicados filtros, que en muchas ocasiones no presenta un rendimiento óptimo cuando se trata de limpiar señales de alta complejidad como las tratadas en este trabajo, además al contar con estas herramientas de trabajo, la selección de información relevante y la clasificación de la misma se hace un poco más sencilla permitiendo así mejorar la eficiencia del dispositivo, en conclusión las técnicas de procesamiento

e inteligencia artificial contienen la clave para hacer de este dispositivo un dispositivo más asequible para la población en general.

Este trabajo presenta la implementación un dispositivo de bajo costo con la capacidad de adquirir y procesar señales EEG valiéndose de un sistema de adquisición sencillo y un sistema embebido (Raspberry Pi 3), el cual haría toda la parte de procesamiento y clasificación de las señales, a continuación, se documenta la metodología utilizada para la realización de esta tarea.

2. Sistema de adquisición

Es la etapa encargada de tomar las señales obtenidas por los electrodos y llevarlas a un formato digital para su posterior análisis, se implementó una etapa de multiplexado que le brinda al sistema la posibilidad de trabajar con varios canales de manera simultánea, una fase de amplificación, un filtro pasa banda para limitar el rango de frecuencias que pueden pasar por el sistema, ajuste de nivel DC para que la conversión se haga mucho más eficientemente sin perder información importante, para finalizar se utilizó un ADC llevando las señales a un sistema embebido para acondicionar y procesar esta información, en la Figura 1 se puede ver la metodología implementada.



Figura 1. Diagrama en bloques para la adquisición de las señales de electroencefalografías.

Fuente: elaboración propia.

3. Diseño del experimento y preparación del paciente

Para lograr un registro adecuado de las señales EEG hay que tener en cuenta muchos aspectos importantes, entre ellos el diseño del experimento y la preparación del paciente, se ha diseñado tres experimentos diferentes, el primero con el propósito de validar el sistema en función de la variación de las ondas alfa del cerebro, dependiendo del estado de ánimo del paciente, se ha llevado el

paciente a un estado de relajación y un estado de alerta, para luego realizar el registro de las señales.

Para el segundo experimento se expuso el paciente a tres diferentes estímulos visuales diferentes, el estímulo visual consistía en hacer aparecer una imagen de color de manera repentina a una frecuencia constante, con tres colores diferentes, como se puede ver en la Figura 2.

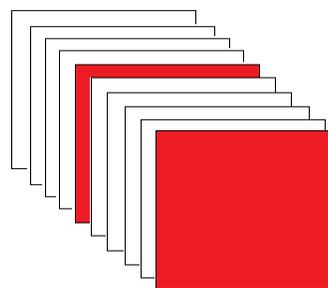


Figura 2. Diseño del estímulo visual.

Fuente: elaboración propia.

Para el estímulo auditivo, experimento tres se mantuvo la misma metodología que para el experimento dos con la diferencia que había etapas de silencio y sonido a diferentes frecuencias elegidas por los autores como se muestra en la Figura 3.

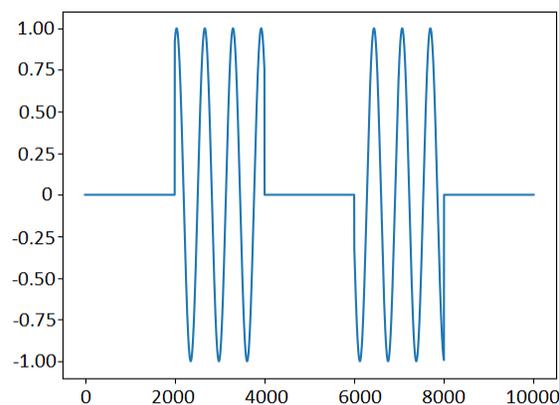


Figura 3. Diseño del estímulo auditivo.

Fuente: elaboración propia.

Todas las señales fueron registradas de forma controlada asegurando la máxima colaboración por parte del paciente y su respectiva preparación, teniendo en cuenta aspectos como la limpieza del cuero cabelludo, la no presencia de productos capilares en el cabello que pudiera aumentar la impedancia entre el electrodo y la piel, se mantuvo una impedancia no mayor a $5K\Omega$ [19].

4. Extracción de características

4.1. Análisis Multi-resolución Wavelet

Consiste en aplicar la transformada discreta Wavelet ecuación 1 varios niveles, teniendo en cuenta los coeficientes de detalle y de aproximación.

$$C_{(A,D)}(n) = \sum_{A,D} x(n) * \varphi \left[\frac{n-A}{D} \right] \quad (1)$$

Los datos obtenidos son introducidos a un clasificador con el objetivo de buscar el nivel de descomposición más adecuado para el análisis de las señales (Figura 4), teniendo como parámetro para la selección de dicho nivel el porcentaje de clasificación obtenido con un grupo de datos de entrenamiento previamente seleccionados.

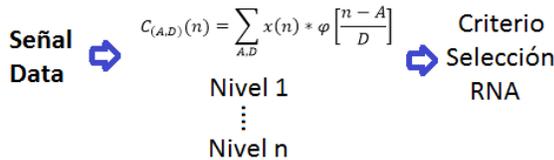


Figura 4. Selección de la mejor basado en DWT. Fuente: elaboración propia.

4.2. Selección de la mejor base

Para esta selección se utilizó la metodología propuesta por los autores [9], la cual consiste en aplicar entropía tanto a la wavelet base, como a sus niveles hijos (aproximación y detalle), seleccionando la de menor entropía, partiendo de su nivel más refinado. Es este trabajo se usaron familias wavelet madre duabechies, coiflets y symlet, y fue tomada como referencia la wavelet madre db5 (Figura 5).

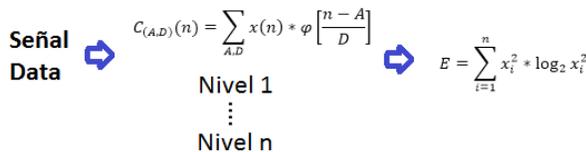


Figura 5. Selección de la mejor base en Entropía. Fuente: elaboración propia.

4.3. Caracterización de los estímulos visuales y auditivos

En esta fase se buscaba poder encontrar el potencial evocado, propio al estímulo visual o auditivo diseñado. Debido a que los potenciales evocados presentan una amplitud mucho menor de entre 1-20uV en comparación con el EEG normal entre 50-100uV, además la actividad cerebral para el EEG es aleatoria y para los PE

generalmente es constante [16], se procedió a realizar una resta promedio entre dos conjuntos de señales s1 y s2 sincronizadas al momento de registrar la señal (ecuación (2)), esto con el propósito de ubicar las zonas donde se encuentra el potencial evocado.

$$X = \left(\frac{1}{L} \sum_{i=1}^L S1_i \right) - \left(\frac{1}{L} \sum_{i=1}^L S2_i \right) \quad (2)$$

5. Clasificación

Para la clasificación de las señales obtenidas se tomaron 5 muestras aleatoria de cada experimento y para cada caso, se entrenó una red neuronal que usa como método el descenso por gradiente estático para minimizar el error, y una máquina de soporte vectorial, utilizando como función Kernel un polinomio de grado 5 como se muestra en la Figura 6, para el caso 1 la salida corresponde a la predicción del estado del paciente según el comportamiento de sus ondas alpha, para los casos 2 y 3 la salida corresponde a la predicción del estímulo al cual está expuesto el paciente.

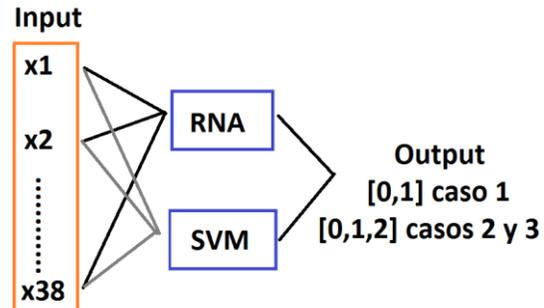


Figura 6. Máquinas de aprendizaje utilizadas para la clasificación de las señales. Fuente: elaboración propia.

Como forma de mejorar la eficiencia de los clasificadores se variaron los datos de entrenamiento basados en los porcentajes de clasificación, para seleccionar las muestras más representativas, además de esto se calculó la desviación estándar (ecuación (3)) manteniéndola en un rango no superior a 1, puesto que los resultados se pueden ver afectados por este parámetro.

$$D = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}} \quad (3)$$

6. Resultados

En esta fase se muestra los resultados obtenidos con las diferentes metodologías implementadas, La fase uno del

sistema se remonta al diseño electrónico del mismo, en la Figura 7 se muestra el diseño final, esta tarjeta está compuesta por la etapa de multiplexado, amplificación, filtrado, ajuste nivel DC y conversión análogo digital, como también una etapa de regulación, para garantizar que no hallan variaciones en el voltaje de alimentación y el sistema pueda funcionar con baterías, haciéndolo portátil y eliminando el ruido de 60Hz producido por la red eléctrica.



Figura 7. Diseño electrónico para adquisición de Señales EEG usando el software Eagle 8.0.1. Fuente: elaboración propia.

En la Figura 8 se muestra el resultado de la clasificación al ingresar 20 señales de un paciente cuyas señales no hacían parte de la data de entrenamiento, estas señales estaban conformadas por 10 señales donde el paciente estuvo en un estado de relajación y 10 señales donde el paciente se mantuvo alerta a su entorno.

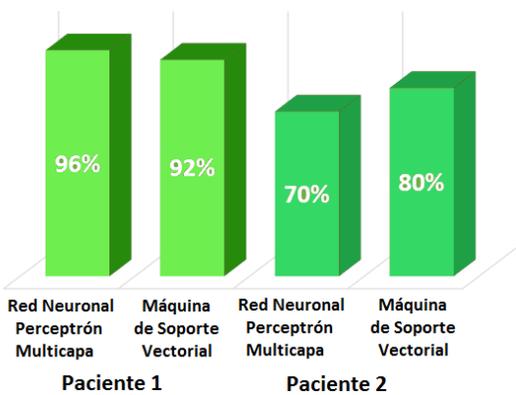


Figura 8. Porcentaje de clasificación obtenido al validar el sistema. Fuente: elaboración propia.

En la Figura 9 se muestra la comparación del método de entropía para seleccionar la mejor base propuesta por Coifman [20] (método 1), y el método de descomposición por análisis multi-resolución basados en los porcentajes de clasificación aplicada para seleccionar la mejor base (método 2). Se puede observar que para ambos casos se presentaron porcentajes de clasificación

similares, dejando ver que ambos métodos son adecuados para seleccionar la base de descomposición adecuada, estos porcentajes de clasificación es el resultado de entrenar una SVM con 5 datos de cada tipo de señal y clasificar 15 señales nuevas, para hacer un total de 25 datos.

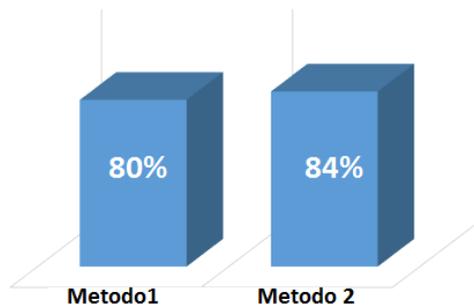


Figura 9. Porcentaje de clasificación utilizando diferentes bases de descomposición Wavelet. Fuente: elaboración propia.

En la Figura 10 a) se muestra el patrón que mayor porcentaje de clasificación obtuvo al momento de clasificar las señales para el paciente 1 y en la Figura 10 b) para el paciente 2, para el experimento de validación se tomó el nivel de descomposición 10 de la señal, uno de sus coeficientes de aproximación, puesto que presenta menor número de datos y logra un porcentaje de clasificación un poco mayor.

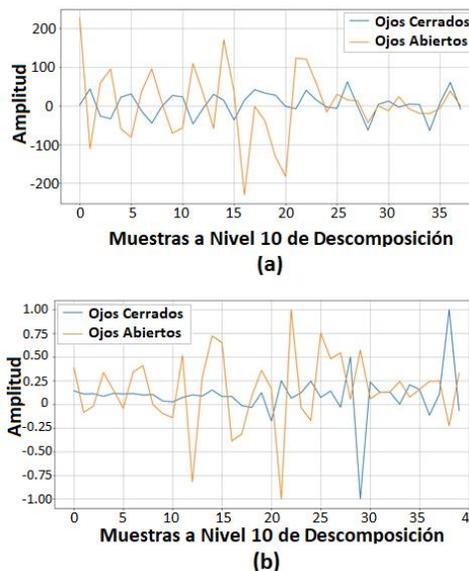


Figura 10. Patrón utilizado para la clasificación de las señales (ojos abiertos y ojos cerrados) experimento 1. Fuente: elaboración propia.

Para la detección del potencial evocado proveniente del experimento 2, se restaron dos señales registradas dando como resultado la identificación del lugar donde se presenta el potencial evocado, esto se observa en la Figura 11. Nótese como en los círculos rojos se observa las posiciones donde se produjo el potencial evocado proveniente de una imagen de color rojo.

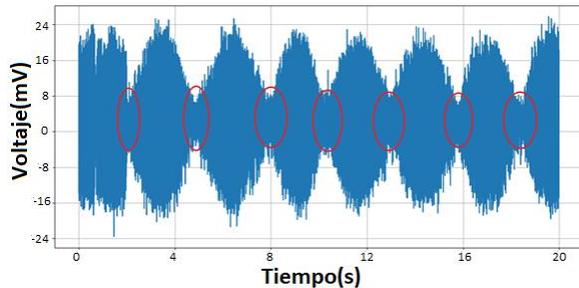


Figura 11. Zonas donde se presenta el potencial evocado. Fuente: elaboración propia.

Para la clasificación de los estímulos visuales y auditivos, se realizó una descomposición wavelet, teniendo en cuenta las variaciones que tenía la señal, en la Figura 12 se muestra el resultado obtenido para una descomposición wavelet nivel 7 en sus coeficientes de aproximación para estímulos auditivos, las señales color verde representan al estímulo auditivo de 500Hz, las de color azul al estímulo de 1Khz y las señales amarillas a estímulos cuyos sonidos presentan varias componentes de frecuencia.

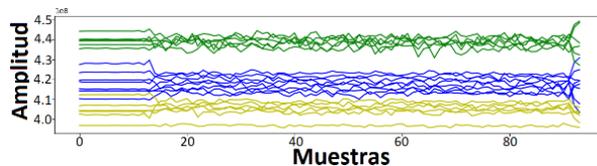


Figura 12. Estímulos auditivos a una descomposición 7 de Wavelet. Fuente: elaboración propia.

De manera similar sucede con los estímulos visuales, en la Figura 13 se muestra el resultado, donde el color de cada señal representa su respectivo color en cada estímulo.

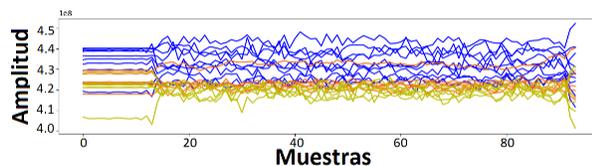


Figura 13. Estímulos visuales a una descomposición 7 de Wavelet. Fuente: elaboración propia.

7. Conclusiones

Las señales EEG son señales bioeléctricas producidas por la actividad cerebral. Estas señales aportan información acerca del funcionamiento y características de este, debido al elevado número de personas que sufren algún tipo de discapacidad motriz y la existente necesidad de ayudar a mejorar su calidad de vida se han creado nuevas técnicas y metodologías para el análisis de señales cerebrales.

La gran mayoría de trabajos existentes hacen referencia al análisis de estas señales sin tener en cuenta el factor económico y la portabilidad, parámetros de gran importancia para una gran parte de la población que sufren estas afecciones, en la actualidad existen dispositivos capaces de adquirir y procesar señales EEG utilizando tecnología muy avanzada, llegando a ser inaccesible para la mayoría de la población, sin mencionar para la movilidad de estos dispositivos generalmente es nula haciendo más difícil implementarlo en aplicaciones reales de la vida cotidiana, claramente es necesario investigar más acerca de nuevas metodologías de filtrado y técnicas de inteligencia artificial para aumentar el índice de confiabilidad de estos análisis y a su vez disminuir costos en la fabricación de estos equipos, como se demuestra en la investigación es posible registrar señales EEG utilizando tecnologías comunes y de bajo costo, implementando técnicas de procesamiento de señales como el análisis multi-resolución de wavelet entre otras técnicas que no requieren de una maquina muy potente para trabajar de manera correcta.

Referencias

- [1] P. Konrad, T. Shanks, "Implantable brain computer interface: Challenges to neurotechnology translation," *Neurobiol. Dis.*, vol. 38, no. 3, pp. 369–375, 2010, doi: 10.1016/j.nbd.2009.12.007
- [2] J. F. D. Saa, J. R. Escorcia Gutiérrez, J. D. M. Rocha, "Diseño y Construcción de un Electroencefalógrafo de 32 Canales," *Partnering to Success Eng. Educ. Res. Dev.*, p. 8, 2008.
- [3] L. H. Francisco, E. L. Johan, H. M. A. Leobardo, Z. I. Carlos, S. C. Susana, "Distribución de la densidad de corriente e impedancia de materiales alternativos en microelectrodos mediante el análisis de elemento finito," *en IFMBE Proceedings*, 2013, vol. 33 IFMBE, pp. 975–978, doi: 10.1007/978-3-642-21198-0_248
- [4] G. Borja, T. Ortega, A. Romero, "Design and Implementation of an equipment for the acquisition and

visualization in pc of electroencephalographs,” *Prospectiva*, vol. 8, n° 1, pp. 21-28, 2010.

[5] R. Barea Navarro, “Instrumentación Biomédica,” tesis doctoral, Universidad de Alcalá, Madrid, España.

[6] A. Larrazábal, R. Acevedo, L. Rufiner, “Mejoramiento de la relación señal a ruido en potenciales evocados mediante métodos de regulación,” *Revista Argentina de Bioingeniería*, vol. 18, no. 1, pp. 9-14, 2012.

[7] A. E. Donoso, “Reducción de artefactos oculares en señales EEG: fieltado adaptativo como alternativa a la regresión lineal,” [En línea]. Disponible en: <https://hal.archives-ouvertes.fr/hal-00419918>

[8] L. Alvares Escobar, “Análisis de Esquema de Filtrado para señales Electrocardiográfica (ECG),” proyecto de grado, Universidad Tecnológica de Pereira, Risaralda, 2007.

[9] B. A. Medina, R. Álvarez López, “Caracterización de Señales EEG mediante Wavelet Packet y Entropía Difusa para tareas de imaginación motora,” *Ingeniería*, vol. 22, no. 2, p. 226, May 2017, doi: 10.14483/udistrital.jour.reving.2017.2.a04

[10] K. J. Acuña Condori, “Procesamiento de señales electroencefalográficas en un sistema embebido para una interfaz cerebro máquina,” tesis posgrado, Pontificia Universidad Católica de Perú, 2017.

[11] J. Torre Abauita, “Procesado de señales EEG para una interfaz cerebro maquina (BCI),” tesis pregrado, Universidad Carlos III de Madrid, España, 2012.

[12] J. A. Cuartas, P. A. Madrigal, R. A. Torres, “Interfaz cerebro computador controlada por sincronización y desincronización relacionada a eventos en sujetos no entrenados,” in *IFMBE Proceedings*, 2013, vol. 33 IFMBE, pp. 611–614, doi: 10.1007/978-3-642-21198-0_156

[13] J. D. Asimbaya Molina, J. A. Suasnavas Tipan, “Diseño e implementación de un prototipo Brain Computer Interface(BCI), para la manipulación de una pinza robótica utilizando comunicación Bluetooth,” trabajo de grado, Universidad Politécnica Salesiana, Quito, Ecuador, 2014.

[14] S. Mourente Diaz, “Potenciales evocados auditivos de latencia media en el trastorno por déficit de atención e hiperactividad tipología y pronóstico de la

respuesta al tratamiento,” tesis de doctorado, Universidad de Santiago de Compostela, España, 2008.

[15] L. Lorenzo López, “Psicología de atención visual y envejecimiento estudio mediante potenciales evocados,” Santiago de Compostela, España, 2007.

[16] L. Muñoz Peña, J. Corral, “Potenciales Evocados Cerebrales en el Contexto de la Investigación Psicología: una Actualización,” *Anuario de Psicología*, vol. 35, n° 1, pp. 3–21, 2004.

[17] A. Moran García, “Diseño de Interfaces Cerebro-Máquina Controlados Mediante Registros de EEG,” tesis pregrado, Universidad Autónoma de Madrid, España, 2015.

[18] L. F. Nicolas-Alonso, J. Gomez-Gil, “The National Center for Biotechnology Information,” 2012. [En línea]. Disponible: <http://www.ncbi.nlm.nih.gov/pmc/articles/PMC33044110/>

[19] R. Acevedo, “Técnicas para Detección y Estimación Eficiente de Potenciales Evocados,” *CDyTS*, vol. 8, no. 8, 2018.

[20] N. Debasish, M. J. Singh, S. Sahoo, J. Hazarika, “Wavelet Based De-noising of EEG Signal Acquired from Tele-serial Addicted Persons,” in *3rd International Conference on Recent Developments in Control, Automation & Power Engineering (RDCAPE) de 2019*, pp. 265-269, doi: 10.1109/rdcape47089.2019.8979060