

## Modelado autorregresivo de señales electroencefalográficas para simuladores médicos

### Autoregressive modelling of electroencephalographic signals for medical simulators

Frank Sánchez\*

Alher Mauricio Hernández\*\*

*Universidad de Antioquia, Medellín, Colombia*

\* Bioingeniero de la Universidad de Antioquia (2014). Durante el año 2015 se desempeñó como joven investigador e innovador Colciencias en el Grupo de Investigación en Bioinstrumentación e Ingeniería Clínica (GIBIC). Actualmente es ingeniero de investigación y desarrollo en el Grupo de Investigación Bioinstrumentación e Ingeniería Clínica (GIBIC), Programa de Bioingeniería, Facultad de Ingeniería, Universidad de Antioquia UdeA; Calle 70 No. 52-21, Medellín, Colombia. Sus actividades de investigación se enfocan en el procesamiento de señales biomédicas y el modelado y la simulación de procesos fisiológicos. *frank.sanchezr@udea.edu.co*

\*\* Ingeniero Electrónico de la Universidad de Antioquia (1996) y Ph.D. en Ingeniería Biomédica de la Universidad Politécnica de Cataluña (2007). Desde 2007 ha sido docente investigador del Programa de Bioingeniería de la Universidad de Antioquia en donde imparte cursos de procesamiento de señales y modelado de sistemas biomédicos. Fue coordinador del programa de Bioingeniería de la Universidad de Antioquia (2010-2014), actualmente es el director del Grupo de Investigación en Bioinstrumentación e Ingeniería Clínica (Gibic) de la misma universidad en Medellín, Colombia. Pertenece al BIOSignal Analysis for Rehabilitation and Therapy Research Group (Bioart) de la Universidad Politécnica de Cataluña. *alher.hernandez@udea.edu.co*

**Origen de subvenciones:** Este trabajo ha sido financiado por el Fondo Nacional de Regalías de la República de Colombia (convenio 139C), titulado "Fortalecimiento de la plataforma tecnológica para la formación especializada en salud y el desarrollo de tecnología biomédica", la Universidad de Antioquia y por Colciencias con su programa "Jóvenes investigadores e innovadores" (JIC-118-2014). El trabajo se desarrolló durante la ejecución del proyecto en los años 2014 y 2015.

## Resumen

El registro de la actividad eléctrica cerebral ha permitido la comprensión de diferentes estados neurofisiológicos, posibilitando el diagnóstico de algunos trastornos neuronales, de aquí, la importancia de la caracterización y el conocimiento de las diferentes morfologías que pueden presentar las señales de electroencefalografía (EEG). El modelado matemático de señales biomédicas facilita el desarrollo de simuladores que pueden servir como herramienta de entrenamiento médico en computadores o dispositivos móviles. Este artículo presenta el modelado paramétrico autorregresivo (AR) y la simulación de señales EEG en diferentes estados fisiológicos, como: reposo con ojos abiertos y cerrados y crisis epilépticas, además bajo la presencia de algunos de los artefactos más comunes, como son: parpadeo, actividad muscular, electrodo "pop" y ruido 60 Hz. Se valida el desempeño de los modelos en el dominio del tiempo a través del porcentaje de ajuste FIT, el cual siempre estuvo por encima del 70%, y en el dominio de la frecuencia a través de la energía en las bandas de frecuencia características del EEG. Se presenta la metodología de modelado, los gráficos de las señales simuladas y los valores de los parámetros evaluados. La amplia variedad de señales EEG modeladas permitirá el desarrollo de simuladores de señales cerebrales para el entrenamiento del personal médico, e igualmente para el análisis y la caracterización de las señales de electroencefalografía.

**Palabras clave:** Electroencefalografía, modelado de señales, procesos autorregresivos, simuladores médicos.

## Abstract

The recording of brain electrical activity has led to a greater understanding of different neurophysiological states, has even made possible the diagnosis of some neuronal disorders, hence the importance of characterization and understanding of the different morphologies that may have electroencephalography signals (EEG). The mathematical modeling of biomedical signals facilitates the development of simulators that can be useful as medical training tools on computers or mobile devices. This paper presents the autoregressive (AR) modeling and simulation of EEG signals in different physiological states: seizures, resting with eyes open and eyes closed, and also under the presence of some of the most common artifacts: muscle, eye blinking, electrode "pop", and 60-Hz. The performance of the models has been validated in the time domain using the percentage of fitting (FIT), which was always above 70%, and in the frequency domain through energy of the characteristic frequency bands of the EEG. The modeling methodology, figures of simulated signals and the values of the parameters evaluated are presented. The wide variety of EEG signals modeled allow the development of brain signals simulators for training of medical personnel, and also for the analysis and characterization of EEG signals.

**Keywords:** Autoregressive processes, electroencephalography, medical simulators, signal modeling.

Fecha de recepción: 15 de abril de 2016  
Fecha de aceptación: 6 de marzo de 2017

## I. INTRODUCCIÓN

La interpretación de las señales cerebrales a partir de un análisis visual ha permitido al personal médico y a los investigadores un mejor entendimiento de la fisiología del sistema nervioso, logrando incluso el diagnóstico de algunos trastornos cerebrales, así mismo, como los registros de electroencefalografía (EEG) siguen siendo una de las principales herramientas para el desarrollo de la neurología clínica y la neurociencia.

La electroencefalografía es el registro de la actividad eléctrica de un gran número de neuronas a través de electrodos ubicados comúnmente en la superficie del cuero cabelludo. Dicha actividad eléctrica es originada por los potenciales post-sinápticos que ocurren de forma sincronizada en una gran cantidad de neuronas piramidales. La diferencia de potencial debe atravesar diferentes capas de tejido como el cráneo, el líquido cerebroespinal y el tejido subcutáneo, hasta alcanzar los electrodos metálicos que capturan la señal para su posterior procesamiento y visualización [1].

El trazado de EEG puede presentar variaciones en su frecuencia y amplitud de un estado fisiológico a otro, como por ejemplo en la vigilia, el sueño, con la edad, en algunos trastornos neurológicos, entre otros. La profunda inspección visual de las señales EEG ha permitido la caracterización de las ondas de acuerdo a su frecuencia, encontrándose cinco principales rangos de frecuencia denominados ritmos cerebrales: delta (0-4 Hz), theta (4-8 Hz), alfa (8-13 Hz), beta (13-30 Hz) y gamma (> 30 Hz). En relación con la amplitud de las señales, es común que en registros llevados a cabo sobre el cuero cabelludo se encuentre en rangos entre 10  $\mu\text{V}$  y 100  $\mu\text{V}$  [1].

El modelado paramétrico ha sido una técnica muy popular para el análisis de series de tiempo, en especial para señales de origen biológico como el EEG [2]. La técnica de modelado paramétrico permite la caracterización de las series de tiempo a pesar de no utilizar información de la naturaleza de las mismas, por ejemplo, la fisiología o el origen anatómico de las señales. Dentro del modelado paramétrico, los modelos autorregresivos (AR) destacan por su relativa simpleza, en donde la señal en un tiempo específico es descrita como una combinación lineal de sus valores pasados.

En este artículo se presenta el desarrollo de modelos para la simulación de diferentes tipos de señales EEG comúnmente encontradas en la práctica clínica, con miras al desarrollo de simuladores de señales cerebrales que permitan el entrenamiento y aprendizaje del personal médico, siendo el desarrollo de simuladores un área de investigación muy activa, donde incluso, se buscan implementar herramientas de simulación que pueden contribuir como ayudas diagnósticas [3].

En el presente artículo, primero se exponen los conceptos teóricos de las diferentes condiciones de registro y artefactos en EEG que son modelados, enseguida se discuten los métodos empleados para la obtención de los modelos autorregresivos y su posterior simulación, y finalmente se presentan y discuten algunos de los resultados alcanzados.

## II. METODOLOGÍA

En esta sección se describen las características morfológicas más importantes de las señales EEG bajo diferentes condiciones de registro, y algunos de los artefactos más comunes que pueden estar presentes durante un registro de EEG. También se presenta el proceso de identificación con modelos autorregresivos, y finalmente la simulación de las señales EEG a partir de los coeficientes del modelo AR.

### A. Condiciones de registros EEG simuladas

La actividad eléctrica del cerebro puede ser registrada en una gran variedad de condiciones y bajo diferentes estímulos, y para cada caso se puede tener un trazado de EEG con características morfológicas distintivas. En un adulto, bajo condiciones normales y en estado de vigilia, un trazado de EEG presentará distintas morfologías de las ondas dependiendo de si este se realiza con los ojos cerrados o con los ojos abiertos. Durante la condición de ojos cerrados es común encontrar una forma de onda altamente rítmica y sinusoidal con frecuencia predominante en la banda alfa, con mayor amplitud en los canales posteriores y occipitales, este comportamiento es conocido comúnmente como ritmo posterior. Por otra parte, la condición de ojos abiertos se caracteriza por su bajo voltaje, menor a  $20 \mu\text{V}$ , la falta de un patrón en el trazado y la completa ausencia del ritmo posterior [4]. Aquí se han modelado y simulado estos dos estados característicos que son ampliamente usados en la práctica clínica.

Existen muchas situaciones clínicas en las cuales es conveniente llevar a cabo un registro de electroencefalografía, pero una de las razones más comunes para emplear esta técnica es su efectividad en el diagnóstico de la epilepsia; se ha probado que la electroencefalografía es una herramienta muy útil para la clasificación de diferentes tipos de crisis de epilepsia [5], [6], [7]. La clasificación más común de las crisis epilépticas las agrupa en: parciales y generalizadas. A su vez, cada una de estas categorías se divide en otros subgrupos [5]. Se han simulado dos tipos de crisis epilépticas: “Crisis epiléptica parcial compleja”, la cual está confinada en una región del cerebro y en el trazado de EEG solo puede ser apreciada en un grupo de electrodos; los patrones de EEG asociados con crisis parciales suelen consistir en una descarga rítmica y aguda sobre el área afectada, como un tren de espigas, y se pueden presentar tanto a bajas como a altas frecuencias. “Crisis generalizada de ausencia”, la cual distorsiona la actividad eléctrica de la totalidad del cerebro y por lo tanto puede ser observada en todos los canales empleados durante el registro. La característica más importante en el trazado de EEG es la clásica descargar de 3 Hz como frecuencia dominante, encontrándose su máximo voltaje comúnmente en los electrodos frontales y con menor frecuencia en la zona occipital. La amplitud de la descarga normalmente se encuentra por encima de los 100  $\mu$ V. Aunque el término 3 Hz es consistente, a menudo se puede encontrar una frecuencia ligeramente mayor o menor a los 3 Hz [5].

## B. Artefactos en EEG simulados

Un artefacto es una onda en el trazado del EEG que no es de origen cerebral, y pueden clasificarse en artefactos de origen fisiológico y artefactos de origen no fisiológico. Quizá uno de los desafíos más importantes en la lectura de un EEG es la correcta identificación de los artefactos, que conlleva el objetivo de evitar relacionarlos con actividad cerebral real [4]. Los artefactos que se han implementado en el presente trabajo son:

- *Parpadeo*

Este artefacto es producido por el fenómeno de Bell [4], el globo ocular actúa como un dipolo: el polo positivo orientado anteriormente, en la córnea, y el polo negativo orientado posteriormente, en la retina. Cuando un individuo parpadea, el globo ocular rota hacia arriba, generando una

corriente alternante de alta amplitud que es detectada por cualquier electrodo ubicado cerca de los ojos, es decir en la región frontal.

- *Muscular*

Los artefactos de origen muscular se presentan con mayor frecuencia durante un registro llevado a cabo en estado de vigilia. Este artefacto es registrado más a menudo por los electrodos situados sobre los músculos del cuero cabelludo (músculos frontales, temporales y occipitales). Un artefacto muscular comúnmente presenta mayores frecuencias en comparación con el rango de frecuencias característico de las señales de EEG, y puede ser difícil de apreciar una morfología en la onda generada, a manera de una mezcla heterogénea de ondas con una alta amplitud.

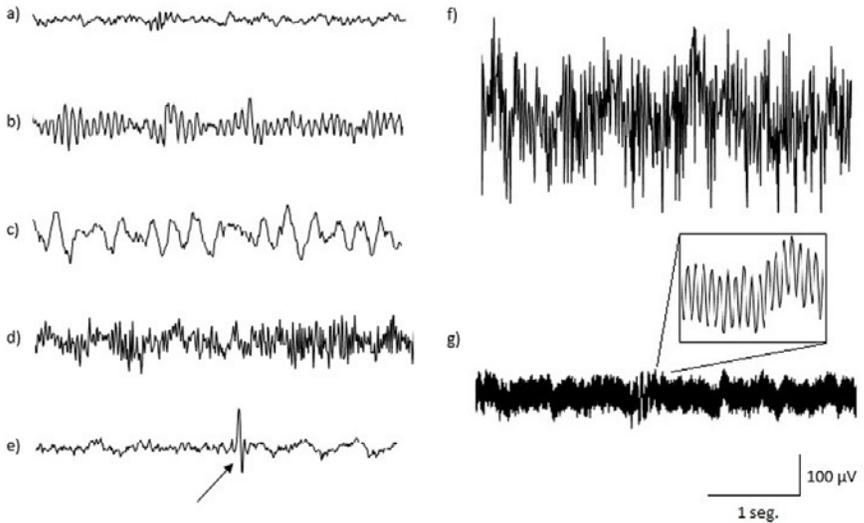
- *Ruido 60 Hz*

Es un artefacto debido a la interferencia eléctrica proveniente del propio equipo de registro o de líneas eléctricas cercanas. El artefacto de 60 Hz puede surgir cuando la impedancia de uno de los electrodos (un pobre contacto del electrodo) es significativamente mayor a la de la tierra eléctrica, y se puede evidenciar tanto en un electrodo aislado como en un conjunto de electrodos.

- *Electrodo "Pop"*

Este artefacto puede ocurrir debido a una acumulación de carga estática en un electrodo individual seguido de una liberación rápida de esa carga, como por ejemplo, un movimiento repentino del lugar de contacto del electrodo. Normalmente la aparición de este artefacto es confinada a un solo electrodo. La forma más característica del artefacto es una rápida descarga de gran amplitud [4].

La Fig. 1 ilustra algunas de las diferentes señales EEG descritas con anterioridad y que son empleadas en el proceso de modelado.

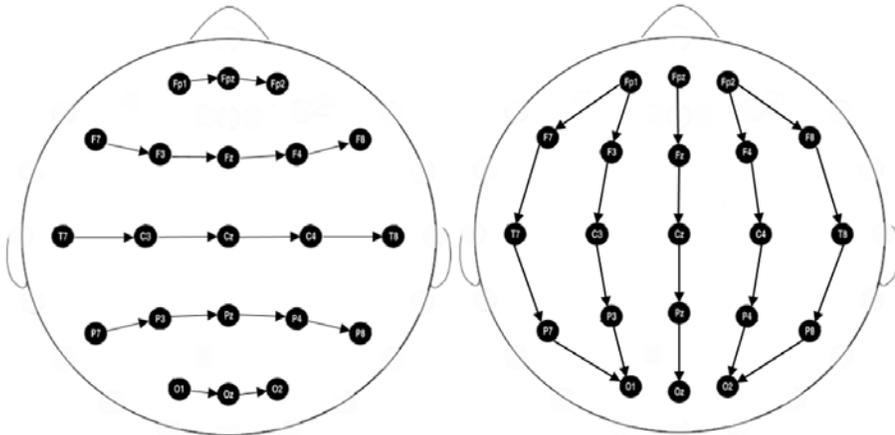


**Figura 1.** Ejemplo de diferentes señales EEG utilizadas para el proceso de modelado: a) señal bajo la condición de vigilia con ojos abiertos, b) señal de electrodo ubicado posteriormente durante la condición de vigilia con ojos cerrados, c) y d) crisis epilépticas, e) artefacto electrodo “pop”, la flecha indica la aparición del artefacto, f) artefacto muscular, g) artefacto ruido 60 Hz.

### C. Registros de EEG

Para llevar a cabo el procedimiento de modelado paramétrico y simulación se han utilizado registros de EEG disponibles en bases de datos públicas [8] para las condiciones en reposo con ojos abiertos y con ojos cerrados. Para el análisis de EEG durante crisis epilépticas se han usado registros realizados por el grupo de investigación Gibic [9]; por último, los artefactos en EEG fueron adquiridos de forma controlada durante diferentes registros realizados con un amplificador Neuroscan (Sistema Médico Neuroscan, Neurosoft Inc. Sterling, VA, EE.UU), empleando el sistema 10-20 y un total de 21 canales. En total fueron analizados ocho registros de EEG, correspondientes a cada una de las condiciones descritas con anterioridad. La Fig. 2 muestra la disposición de los electrodos utilizados, así como los montajes que se han implementado en el presente trabajo que corresponden a los más utilizados en la práctica clínica: a) montaje monopolar, en el cual como referencia se

ha seleccionado los lóbulos de las orejas, y b) montaje bipolar, que a su vez pueden dividirse en longitudinales y transversales. En los montajes bipolares longitudinales se registra la actividad por pares de electrodos organizados en sentido anteroposterior, de adelante hacia atrás; y en los montajes bipolares transversales la actividad eléctrica es registrada por pares de electrodos dispuestos de izquierda a derecha.



**Figura 2.** Nomenclatura y disposición de los 21 electrodos empleados en el sistema 10-20. Izquierda: Montaje transversal. Derecha: Montaje anteroposterior.

#### D. Modelado autorregresivo

Una serie de tiempo proveniente de un proceso estocástico puede ser analizada a través de un modelo paramétrico autorregresivo. Tal modelo expone que la muestra  $x_t$  de una serie de tiempo en un momento dado, puede ser expresada como una sumatoria lineal ponderada de  $p$  valores previos de la serie temporal  $x_{t-1}, x_{t-2}, \dots, x_{t-p}$ , más una componente de incertidumbre o error (Ecuación 1). El valor  $p$  es conocido como el orden del modelo y normalmente se selecciona mucho menor que la cantidad de datos de la serie de tiempo [10].

$$x_t = \sum_{i=1}^p a_i x_{t-i} + \varepsilon_t \quad (1)$$

Donde  $x_t$  es la serie de tiempo,  $\alpha_1, \alpha_2, \dots, \alpha_p$  son los parámetros del modelo autorregresivo de orden  $p$  y el factor  $\varepsilon_t$  es conocido como el error de predicción del proceso, el cual es ruido blanco. Este tipo de modelado paramétrico ha sido ampliamente descrito para el análisis de señales EEG, y su uso se extiende en diferentes temas, como la clasificación y segmentación de señales EEG, la identificación y cancelación de artefactos, la descripción de los diferentes ritmos cerebrales, la simulación y generación de señales EEG, entre otros [11].

Uno de los supuestos más importantes que posee esta técnica de modelado paramétrico y a la vez una limitación, es la condición de estacionariedad del proceso estocástico, que desde el punto de vista estadístico corresponde a cuando su primer y segundo momento, media y varianza respectivamente, no varían con respecto al tiempo [10], [12]. En las señales EEG la estacionariedad depende en gran medida de la longitud de la señal, y se ha encontrado que las señales de EEG pueden ser asumidas localmente estacionarias cuando se analizan en cortos intervalos de tiempo [13]. En este trabajo, para cada registro EEG analizado, a excepción de la condición de parpadeo, se ha estimado un modelo AR por cada canal en un segmento de 2 segundos representativos de la señal. La selección de los segmentos de señal a modelar se realizó verificando visualmente que cumplieran con las características distintivas de la condición de registro en específico, evitando incluir características impropias. El artefacto ocular de parpadeo se ha simulado mediante el ajuste de una ecuación sinusoidal. Todas las señales han sido muestreadas a una frecuencia de 100 Hz. La identificación de los parámetros del modelo autorregresivo se ha llevado a cabo mediante el algoritmo de Burg [14], también conocido como el método de máxima entropía; este algoritmo determina los coeficientes de reflexión y utiliza estos coeficientes para calcular los parámetros del modelo AR de forma recursiva.

El ajuste de un modelo autorregresivo paramétrico a una señal de EEG conlleva básicamente la selección de un único parámetro: el orden del modelo, la elección de un orden muy alto puede producir un sobreajuste del modelo e introducir información incorrecta como falsos picos en el espectro. Por otra parte, un orden de modelo muy bajo puede conducir a la pérdida de información, lo cual en el dominio de la frecuencia se aprecia como un espectro suavizado [12].

Para establecer el orden adecuado del modelo es común el uso de funciones denominadas “criterios de información”. El orden más apropiado para el modelo es aquel que minimice el criterio de información cuando este es evaluado sobre un rango de órdenes dados. Uno de estos criterios de información es el criterio de Hannan-Quinn [15], denotado por  $HQ(p)$  (Ecuación 2). Este criterio es definido como un estimador consistente, el cual converge a su valor verdadero cuando el número de datos tiende al infinito.

$$HQ(p) = \log(V) + \frac{2p \log(\log(N))}{N} \quad (2)$$

Donde  $V$  es la varianza del ruido blanco de entrada,  $N$  es la cantidad de muestras de la señal y  $p$  es el orden del modelo evaluado. La función anterior se compone de dos términos, el primero busca minimizar la varianza del proceso, y el segundo caracteriza el número de parámetros a estimar en el modelo. La interpretación del criterio HQ consiste en que el orden adecuado corresponde al menor valor de HQ cuando se evalúa en un rango de órdenes.

Además, se ha estimado el índice de ajuste o porcentaje de la variación de la salida. Este índice provee una medida del ajuste del modelo a los datos reales (Ecuación 3).

$$FIT = 100 * \left( 1 - \frac{\|x_t - \hat{x}_t\|}{\|x_t - \text{mean}(x_t)\|} \right), \quad [\%] \quad (3)$$

Donde  $x_t$  es la serie de tiempo y  $\hat{x}_t$  es la serie de tiempo simulada a partir de los coeficientes del modelo AR. Valores del FIT cercanos al 100% indican un buen ajuste del modelo, en tanto valores próximos al 0% denotan un modelo inapropiado [16].

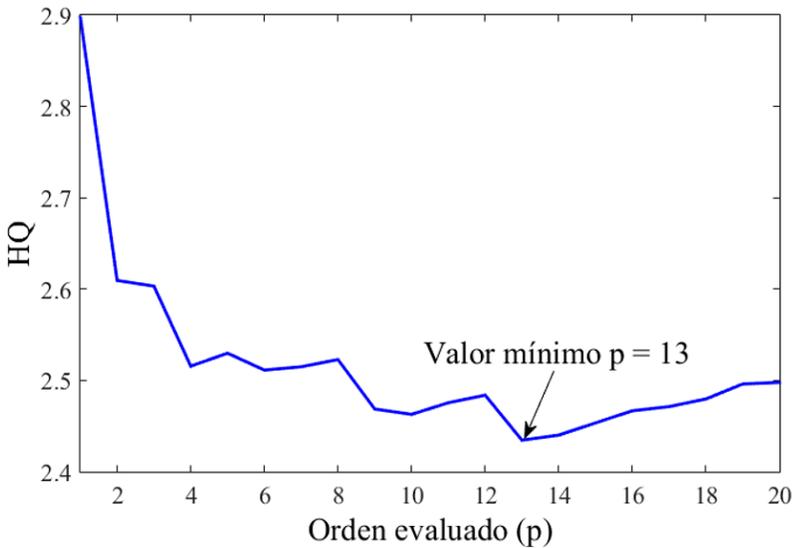
La estabilidad del modelo AR es evaluada a través de los coeficientes de reflexión calculados por el método de Burg, y verifica que la magnitud de dichos coeficientes sea menor o igual a la unidad [14], [17]. Finalmente, se ha estimado la densidad espectral de potencia (PSD), empleando el periodo-

grama de Welch [18], tanto para las señales de EEG originales como para las señales simuladas, lo anterior con el fin de comprobar que las características en el dominio de la frecuencia de las señales simuladas corresponden a las de las señales originales. Para cada espectro se ha obtenido el valor de la energía promedio en cada una de las bandas de frecuencia representativas del EEG, descritas con anterioridad, además se han calculado dos parámetros que brindan información acerca del desplazamiento del espectro de potencia de las señales. Dichos parámetros son la frecuencia media ( $F_m$ ): correspondiente al valor medio de la frecuencia en la PSD, y la frecuencia central ( $F_c$ ): definida como la mediana de la PSD [19].

### III. RESULTADOS Y DISCUSIÓN

En esta sección se presentan los resultados del proceso de modelado autorregresivo de las señales EEG y su validación en los dominios del tiempo y la frecuencia.

La Fig. 3 muestra una tendencia representativa de lo encontrado con la mayoría de canales de EEG registrados con ojos cerrados. En este caso se trata de la señal EEG del canal F3 de la condición en reposo con ojos cerrados, el comportamiento del criterio Hannan-Quinn al ser evaluado en un amplio rango de órdenes, la tendencia de la curva es representativa de los otros canales y de las demás condiciones, y también consistente con otros estudios relacionados con el modelado autorregresivo de señales EEG [20]. A medida que se incrementa el orden, el valor de la función HQ decrece, de la Fig. 3 se puede inferir que un orden del modelo igual a 13 es suficiente para el ajuste del modelo.



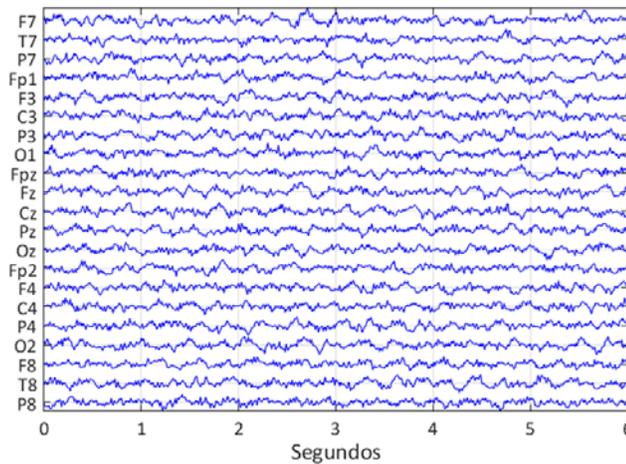
**Figura 3.** Criterio Hannan-Quinn (HQ) como una función del orden del modelo para el canal F3 en condición de ojos cerrados. La forma de la curva es similar para todos los otros canales y en las demás condiciones de registro.

En la Tabla 1, para cada condición de registro se presenta el valor promedio y la desviación estándar del porcentaje de ajuste FIT y del orden del modelo obtenido según el criterio HQ. El valor promedio de ajuste FIT en todos los casos estuvo por encima de 70%, lo cual indica una buena similitud entre las señales EEG reales y las simuladas a partir de los coeficientes de los modelos. Por otro lado, se observa que entre ambas condiciones de vigilia, ojos abiertos y cerrados, el valor del orden del modelo obtenido es similar, asimismo sucede entre ambas condiciones con crisis epilépticas, generalizada y parcial; sin embargo, se aprecia una gran diferencia en el orden del modelo al comparar las condiciones de registro en vigilia con las condiciones de crisis epilépticas. El valor máximo y mínimo encontrado en el orden del modelo para la condición de ojos abiertos fue 16 y 12 respectivamente, en tanto que para la condición de ojos cerrados fue 15 y 10 respectivamente. En relación con la condición de “Crisis epiléptica parcial compleja” se encontró un orden máximo igual a 7 y un orden mínimo igual a 4, para la condición de “Crisis epiléptica generalizada” se obtuvo un valor máximo del orden igual a 8 y un mínimo igual a 3.

**Tabla 1.** Resultados del orden del modelo y del porcentaje de ajuste promedios en cada tipo de registro modelado

Registros EEG modelados	Orden promedio	FIT promedio (%)
Condición reposo ojos cerrados	12,95 ± 1,53	73,96 ± 5,36
Condición reposo ojos abiertos	14,47 ± 1,77	71,14 ± 6,18
EEG Crisis epiléptica generalizada	6,14 ± 2,03	76,29 ± 5,81
EEG Crisis epiléptica parcial compleja	5,12 ± 0,83	70,35 ± 7,12

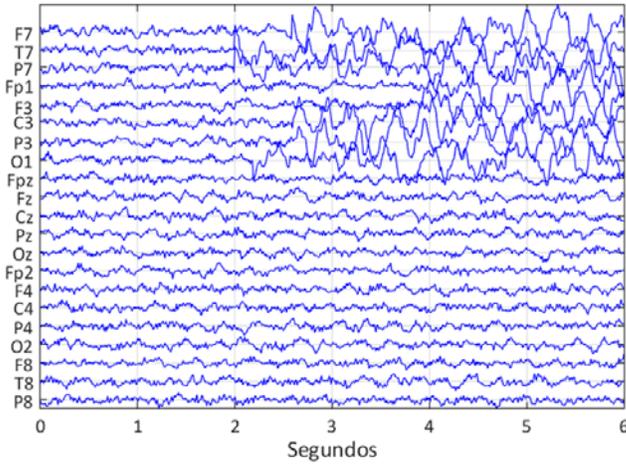
Una vez estimados los coeficientes del modelo AR, según lo descrito en la metodología, se simularon las señales EEG para cada una de las condiciones estudiadas. La Fig. 4 muestra el resultado de la simulación durante 6 segundos de los 21 canales bajo la condición de ojos abiertos, y se evidencia la baja amplitud de la señal y la falta de un patrón característico, lo cual corresponde a esta condición.



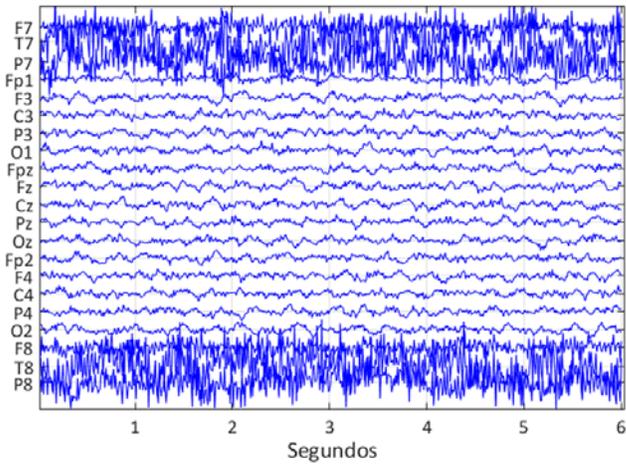
**Figura 4.** Señales EEG simuladas en condición de reposo con ojos abiertos.

La Fig. 5 ilustra el resultado de la simulación de un registro EEG durante una “Crisis epiléptica parcial compleja”, surgiendo en la región temporal izquierda y luego envolviendo por completo el hemisferio izquierdo del cerebro. La forma de onda consiste en un alto voltaje y picos agudos con una destacada baja frecuencia. Por otra parte, la Fig. 6 muestra la presencia de la actividad muscular en la región temporal de ambos hemisferios;

este artefacto muscular aparece como una onda de alta frecuencia y alta amplitud, sin ninguna morfología específica.

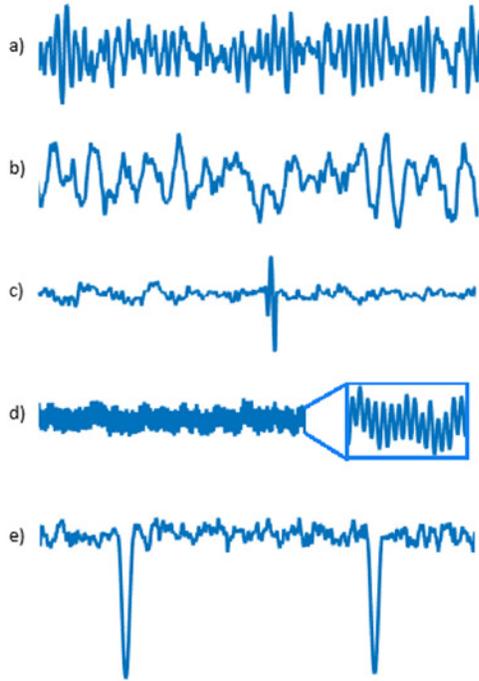


**Figura 5.** Señales EEG simuladas en condición de reposo con ojos abiertos y crisis epiléptica parcial compleja.



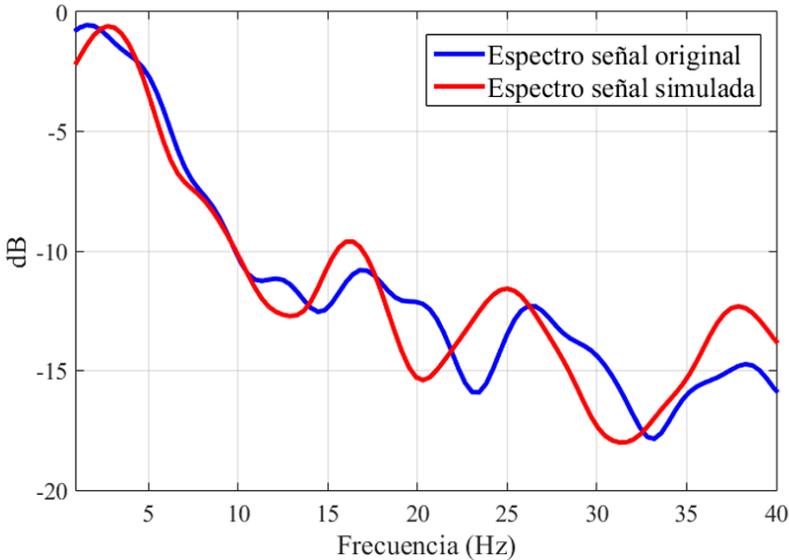
**Figura 6.** Señales EEG simuladas en condición de reposo con ojos abiertos y afectado por artefacto muscular, evidente en los electrodos ubicados en la región temporal de cada hemisferio.

Para las demás condiciones estudiadas se presentan segmentos de señal simulados que incluyen las características más importantes de cada condición, como puede verse en la Fig. 7.



**Figura 7.** Diferentes segmentos de señales EEG simuladas, a) Reposo ojos cerrados, b) Crisis epiléptica, c) Reposo ojos abiertos con artefacto electrodo “pop”, d) Artefacto ruido 60 Hz, e) Reposos ojos abiertos con artefacto parpadeo.

Finalmente, un ejemplo de la densidad espectral de potencia de una señal real y una señal simulada es presentado en la Fig. 8, en donde resulta evidente que el espectro de la señal EEG simulada comparte gran similitud con el espectro de la señal EEG real, siendo este el trazado característico en señales de EEG.



**Figura 8.** Espectro de potencia de la señal real y la señal simulada. Correspondiente al canal F3 de la condición de ojos abiertos.

En la Tabla 2 se presenta para una señal simulada y real de cada condición el valor promedio de la energía en cada una de las bandas de frecuencia del EEG. Igualmente se ilustra el valor de la frecuencia central y la frecuencia media, como parámetros que caracterizan el espectro de potencia. Es evidente que al comparar el valor de la energía promedio entre la señal simulada y real de una misma condición, dichos valores son muy cercanos, igualmente sucede con los valores de la frecuencia central y frecuencia media; lo anterior indica una buena representación de las características en frecuencia por parte de la señal simulada a partir del modelo AR. Resultados similares a los anteriores fueron encontrados para las demás señales de los montajes analizados.

**Tabla 2.** Energía promedio en cada banda de frecuencia y valores de las frecuencias central y media

Señal EEG		Energía promedio [ $\mu V^2$ ]					Frecuencia [Hz]	
		Delta	Theta	Alfa	Beta	Gamma	Fc	Fm
Condición reposo ojos cerrados	Real	0,342	2,428	1,504	0,212	0,025	8,984	10,518
	Simulada	0,323	2,475	1,608	0,199	0,019	8,984	10,588
Condición reposo ojos abiertos	Real	0,734	0,275	0,08	0,051	0,019	4,296	9,428
	Simulada	0,679	0,228	0,07	0,053	0,021	4,296	8,201
Crisis epiléptica generalizada	Real	24,883	4,667	0,924	0,195	0,051	3,125	3,925
	Simulada	24,196	4,196	0,983	0,184	0,046	3,851	4,012
Crisis epiléptica parcial compleja	Real	14,244	4,681	2,238	4,632	0,855	20,703	18,368
	Simulada	13,988	4,391	2,596	4,675	1,048	21,718	18,058

En el trabajo actual se ha desarrollado una metodología para la caracterización de diferentes tipologías de señales EEG empleando el modelado paramétrico autorregresivo. Lo anterior, con el fin de desarrollar simuladores médicos para la formación y el entrenamiento del personal asistencial. En cuanto al modelado autorregresivo como técnica para el análisis y caracterización de señales EEG, diferentes estudios [21], [22] han mostrado la superioridad de este enfoque sobre las técnicas tradicionales no paramétricas, como lo es el periodograma de Welch, resaltando que el modelado paramétrico es mejor para el uso en áreas clínicas y de investigación, debido a que brinda un espectro de frecuencia más claro y de mayor resolución, permitiendo una mejor interpretación de la información. Más en específico, se estima que los modelos AR presentan un mejor desempeño para caracterizar las señales EEG al compararlos con otros métodos paramétricos, como es el caso del modelo Arma (modelo autorregresivo de media móvil) [23]. Aunque existe una amplia variedad de algoritmos para la estimación de los coeficientes del modelo AR, es evidente que el método de Burg ha sido mayormente empleado al obtener buenos resultados [14], [21], [22], [23]. En relación a la estimación del orden del modelo, es importante resaltar que esta depende en gran medida de la cantidad de datos de la señal y de la frecuencia de muestreo de esta, sin embargo, en la gran mayoría de estudios [21], [22], [23] es común el uso de los criterios de información para la estimación idónea del orden del modelo.

#### IV. CONCLUSIONES

En este trabajo se ha presentado una metodología basada en la teoría modelos autorregresivos con el fin de caracterizar diferentes tipos de señales EEG y realizar su posterior simulación en el dominio del tiempo y de la frecuencia. Dichos modelos lograron representar de manera adecuada las características en frecuencia y en tiempo de las señales EEG reales.

Los registros EEG modelados y simulados permitieron consolidar una colección de señales EEG con diferentes patrones morfológicos, según cada condición de registro, que posteriormente pueden ser la base para el desarrollo de simuladores orientados al aprendizaje y la interpretación de señales cerebrales por el personal médico. La estrategia de modelado aquí presentada asume cada canal como una señal aislada proveniente de un proceso cerebral y esto constituye una debilidad de la técnica, pues las señales EEG en realidad se estudian en conjunto. Sin embargo, aun cuando las señales se modelan por separado, se debe garantizar que los modelos simulados correspondan al mismo instante de tiempo. No obstante, los buenos resultados obtenidos permiten trazar una nueva investigación orientada a modelar las señales EEG como un conjunto a través de modelos paramétricos de múltiples salidas en donde se modela el conjunto de señales simultáneamente.

El proceso de modelado aquí presentado tiene otras posibles aplicaciones en clasificación automática de señales EEG, la identificación automática de artefactos, el análisis cuantitativo y la predicción de valores futuros en las señales EEG.

#### REFERENCIAS

- [1] S. Sanei, J. Chambers, *EEG Signal Processing*. 1st ed. England: John Wiley & Sons Ltd, 2007.
- [2] E. Duque, A. Múnera, D. Trujillo, D. Urrego, A. M. Hernández, "System for processing and simulation of brain signals", *IEEE Latin-American Conference on Communications, LATINCOM '09 - Conference Proceedings*, art. 5304853, 2009. doi: 10.1109/LATINCOM.2009.5304853
- [3] H. D. Vargas Cardona, M. A. Álvarez López, A. Ángel Orozco, "Estimación de la propagación eléctrica cerebral generada por la DBS en pacientes con

- enfermedad de Parkinson de la región sur-occidente de Colombia”, *Revista Científica Ingeniería y Desarrollo*, vol 34, no. 2, pp. 116-138, 2016. doi: <http://dx.doi.org/10.14482/inde.34.1.7950>
- [4] D. Schomer, F. da Silva, Niedermeyer’s Electroencephalography: Basic Principles, Clinical Applications, and Related Fields. 6th ed. Philadelphia: Lippincott Williams & Wilkins, 2011.
- [5] M. Libenson, *Practical Approach to Electroencephalography*. 1st ed. Philadelphia: Saunders Elsevier, 2010.
- [6] F. Mormann, R. G. Andrzejak, C. E. Elger, K. Lehnertz, “Seizure prediction: The long and winding road”, *Brain*, vol. 130, no. 2, pp. 314-333, 2007. doi: 10.1093/brain/awl241
- [7] N. Kannathal, M. L. Choo, U. R. Acharya, P. K. Sadasivan, “Entropies for detection of epilepsy in EEG”, *Computer Methods and Programs in Biomedicine*, vol. 80, no. 3, pp. 187-194, 2005. doi: 10.1016/j.cmpb.2005.06.012
- [8] The Neurophysiological Biomarker Toolbox (NBT), [En línea]. Disponible en: <http://www.nbtwiki.net> [Accedido: Abril 9, 2017]
- [9] Bioinstrumentation and Clinical Engineering Research Group (GIBIC), [En línea]. Disponible en: <http://www.gibicgroup.com> [Accedido: Abril 9, 2017]
- [10] K. Blinowska, J. Zygierewicz, *Series in Medical Physics and Biomedical Engineering. Practical Biomedical Signal Analysis Using MATLAB*. 1st ed. Florida: CRC Press. Taylor & Francis Group, 2012.
- [11] V. Lawhern, W. D. Hairston, K. McDowell, M. Westerfield, K. Robbins, “Detection and classification of subject-generated artifacts in EEG signals using autoregressive models”, *Journal of Neuroscience Methods*, vol. 208, no. 2, pp. 181-189, 2012. doi: 10.1016/j.jneumeth.2012.05.017
- [12] J. Muthuswamy, N. Thakor, “Spectral analysis methods for neurological signals”, *Journal of Neuroscience Methods*, vol. 83, no. 1, pp. 1-14, 1998. doi: 10.1016/S0165-0270(98)00065-X
- [13] L. Sörnmo, P. Laguna, *Bioelectrical Signal Processing in Cardiac and Neurological Applications*. 1st ed. California: Elsevier Academic press, 2005.
- [14] J. Pardey, S. Roberts, L. Tarassenko, “A review of parametric modelling techniques for EEG analysis”, *Medical Engineering and Physics*, vol. 18, no. 1, pp. 2-11, 1996. doi: 10.1016/1350-4533(95)00024-0
- [15] E. Hannan, B. Quinn, “The determination of the order of an autoregression”, *Journal of the Royal Statistical Society*, vol. 41, no. 2, pp. 190-195, 1979.

- [16] S. Prívará, Z. Váňa, E. Žáčková, J. Cigler, "Building modeling: Selection of the most appropriate model for predictive control", *Energy and Buildings*, vol. 55, no. 1, pp. 341-350, 2012. doi: 10.1016/j.enbuild.2012.08.040
- [17] B. H. Jansen., J. R. Bourne, J. W. Ward, "Autoregressive estimation of short segment spectra for computerized eeg analysis", *IEEE Transactions on Biomedical Engineering*, vol. 28, no. 9, pp. 630-638, 1981. doi: 10.1109/TBME.1981.324753
- [18] J. Semmlow, B. Griffel, *Biosignal and Medical Image Processing*. 3rd ed. Florida: CRC press. Taylor & Francis Group, 2014.
- [19] I. C. Muñoz, "Evaluación de índices para el destete de la ventilación mecánica en pacientes postquirúrgicos de cirugía cardiovascular utilizando análisis de actividad muscular respiratoria y mecánica ventilatoria", M.S. tesis, Facultad de Ingeniería, Universidad de Antioquia, Medellín, Colombia, 2014.
- [20] M. Ding, S. L. Bressler, W. Yang, H. Liang, "Short-window spectral analysis of cortical event-related potentials by adaptive multivariate autoregressive modeling: data preprocessing, model validation, and variability assessment", *Biological Cybernetics*, vol. 83, no. 1, pp. 35-45, 2000. doi: 10.1007/s004229900137
- [21] M. Akin, M. K. Kiymik, "Application of periodogram and AR spectral analysis to EEG signals", *Journal of Medical Systems*, vol. 24, no. 4, pp. 247-256, 2000. doi: 10.1023/A:1005553931564
- [22] O. Faust, R. U. Acharya, A. R. Allen, C. M. Lin, "Analysis of EEG signals during epileptic and alcoholic states using AR modeling techniques", *ITBM-RBM*, vol. 29, no. 1, pp. 44-52, 2008. doi: 10.1016/j.rbmret.2007.11.003
- [23] S.-Y. Tseng, R.-C. Chen, F.-C. Chong, T.-S. Kuo, "Evaluation of parametric methods in EEG signal analysis", *Medical Engineering and Physics*, vol. 17, no. 1, pp. 71-78, 1995. doi: 10.1016/1350-4533(95)90380-T