

## **CLASIFICACION DE SEÑALES DE ELECTROENCEFALOGRAMA PARA DIAGNOSTICAR DEPRESION**

### **CLASSIFICATION OF EEG SIGNALS FOR DIAGNOSING DEPRESSION**

Gerardo Luna Guevara

Departamento de Psiquiatría y Salud Mental, Facultad de Medicina, Universidad Nacional Autónoma de México

[gerlg@unam.mx](mailto:gerlg@unam.mx)

Electroencefalograma. Diagnóstico. Depresión. Análisis de componentes principales. Análisis lineal de discriminantes.

Electroencephalogram. Diagnosis. Depression. Principal component analysis. Linear discriminant analysis

#### **RESUMEN**

Existe un creciente interés en analizar señales de electroencefalograma (EEG) con el objetivo de clasificar pacientes con alguna sintomatología en particular a partir de un grupo de control. En este estudio, se usó la señal del EEG de pacientes normales y pacientes con depresión para realizar una clasificación por medio de un método conjunto de análisis de componentes principales (PCA) y análisis discriminante lineal (LDA). La señal del EEG es registrada en pacientes en condiciones ambulatorias. Se presenta el cálculo de un perfil estadístico a partir de una serie de señales de alta dimensión provenientes de 9 sujetos sanos y 14 sujetos con depresión. Se emplea el PCA para reducir la dimensión de los datos y de la complejidad estadística, con los valores del PCA obtenidos, valores singulares, se puede caracterizar a los dos grupos de individuos. Mediante el método de clasificación LDA se obtuvo un diagnóstico. Los resultados muestran una alta tasa de aciertos diagnóstico-clasificación dado que la característica del patrón cerebral asociado con la patología depresiva es diferente con aquella correspondiente a sujetos sanos.

#### **ABSTRACT**

There is growing interest in analyzing signals of electroencephalogram (EEG) with the objective to classify patients with some symptoms in particular from a control group. In this study, EEG signals from normal patients and patients with depression was used for sorting by means of an assembly method of principal component analysis (PCA), linear discriminant analysis (LDA). The EEG signal is recorded in patients in ambulatory conditions. Calculating a statistical profile comes from a series of high-dimensional signals from nine healthy subjects and 14 patients with depression. PCA is employed to reduce the dimension of the data and statistical complexity, with the values obtained from PCA, singular values, can characterize the two groups of individuals. By sorting method LDA diagnosis was obtained. The results show a high rate of correct diagnosis-rated since the characteristic brain pattern associated with depressive disorders is different with that of healthy subjects.

# CLASIFICACION DE SEÑALES DE ELECTROENCEFALOGRAMA PARA DIAGNOSTICAR DEPRESION

## 1. INTRODUCCIÓN

Los electroencefalogramas (EEG) son el registro y la evaluación de los potenciales eléctricos producidos por el cerebro y obtenidos por medio de electrodos. El análisis de la actividad EEG se ha logrado principalmente en entornos clínicos para identificar patologías y epilepsias desde el estudio por Hans Berger de la actividad eléctrica rítmica en el cuero cabelludo humano<sup>1</sup>. En el pasado, la interpretación de la EEG se limita a la inspección visual por un neurofisiólogo, un individuo entrenado para hacer una distinción cualitativa entre la actividad EEG normal y alteraciones contenidas dentro de los registros de EEG. El avance en las computadoras y las tecnologías relacionadas con ellos ha hecho que sea posible aplicar con éxito una serie de métodos para cuantificar cambios en el EEG<sup>2</sup>.

En comparación con otras señales biomédicas, el EEG es extremadamente difícil para un observador no entrenado entender la asignación espacial de funciones en diferentes regiones del cerebro. Además, el procesamiento de datos puede determinar las características reducidas del conjunto incluyendo sólo los datos necesarios para la cuantificación, como en estudios de respuesta evocada, o extracción de la característica y reconocimiento posterior, como en la detección de pico automatizado durante el monitoreo para la actividad de ataque epiléptico. En los primeros intentos para mostrar una relación entre el EEG y el comportamiento, analizadores de frecuencia analógica se utilizaron para examinar los datos de EEG.

Entre los desórdenes médicos la depresión es una de las más frecuentes, sea aisladamente o en comorbidad con otras entidades clínicas<sup>3</sup>. Es una enfermedad que, generalmente, pasa desapercibida tanto para los profesionales cuanto para las familias, perjudicando los resultados en la atención al paciente, siendo la segunda principal causa de incapacidad, a nivel mundial, para el año 2020, apenas superada por las enfermedades cardíacas<sup>3-4</sup>.

Esta situación, considerada un problema grave de salud pública, es un asunto que, por las proporciones que puede asumir, está llevando a los especialistas, a encontrar nuevas estrategias para enfrentarla y una forma de esta es un hacer un diagnóstico preciso.

Este trabajo es un ejercicio de clasificación supervisada de patrones en el dominio del tiempo de un estudio de electroencefalografía donde se tienen dos grupos de pacientes y se conoce el diagnóstico, para el caso se tiene un grupo de control.

Una interesante aplicación de la tecnología de predicción es su potencial para su uso en dispositivos que conllevan la intervención para un tratamiento adecuado y en tiempo. Análisis de componentes principales (PCA), análisis de componentes independientes (ICA) y el análisis discriminante lineal (LDA) son métodos bien conocidos para la extracción de la característica<sup>5-6</sup>. La extracción de características consiste en transformar las características existentes en un espacio de dimensión reducida que es útil para evitar la redundancia debido a datos

# **CLASIFICACION DE SEÑALES DE ELECTROENCEFALOGRAMA PARA DIAGNOSTICAR DEPRESION**

multidimensionales. Descomposición en valores singulares (SVD) es una técnica de análisis multivariado de datos y los datos del EEG son muy adecuados para análisis usando SVD y PCA<sup>7</sup>. Un único estudio de EEG puede generar miles de mediciones, o incluso decenas de miles de datos. Los datos del estudio de EEG se presentan con ruido y SVD puede detectar y extraer pequeñas señales de datos ruidosos.

El objetivo general de este trabajo es aplicar el análisis SVD y PCA para realizar una clasificación de señales de EEG por medio de LDA. Se describen los métodos de PCA y LDA para el análisis de los datos del EEG, la representación de los datos utilizando un menor número de variables y la detección de patrones de expresión patológica. Los objetivos específicos son: 1) proporcionar una descripción de la aplicación de métodos SVD y PCA y su interpretación; 2) proporcionar un perfil característico con significancia estadística que explique las diferencias y semejanzas entre pacientes con depresión y normales; 3) construir una regla discriminante que permita realizar un diagnóstico de pacientes potenciales con depresión; 4) establecer una base de datos de patrones a partir de la caracterización del EEG.

## **2. METODOLOGÍA**

### **2.1 Sujetos y Base de datos**

El registro de las señales EEG para cada sujeto se realizó con 19 canales a partir de electrodos adheridos con pasta conductora a la superficie de la cabeza. La diferencia de potencial se midió con respecto a una referencia monopolar. La señal se digitalizó con una frecuencia de muestreo de 200 Hz y conversión A/D de 16 bits, filtrada digitalmente entre 0,5 Hz y 30 Hz. De acuerdo al sistema 10-20 los electrodos empleados: Fp1, F3, C3, P3, O1, F7, T3, T6, Fp2, F4, C4, P4, O2, F8, T4, T7, Fz, Cz, Pz<sup>8-9</sup>. Para el análisis, se realizaron registros de 30 minutos de tiempo de actividad en reposo de 9 sujetos sanos, 14 pacientes con depresión para inicio de tratamiento médico. Los pacientes fueron diagnosticados según criterios del DSM-IV<sup>10</sup>, y criterios del CIE-10<sup>11</sup> para un diagnóstico de trastornos del humor. Los registros de EEG se realizaron en la Facultad de Medicina de la UNAM ciudad de México.

Previa a la fase de clasificación de las señales registradas, es necesario extraer de dichas señales la información relevante para la identificación de los patrones.

Las señales de EEG registradas están constituidas por la superposición de una multitud de potenciales individuales de las células nerviosas del cerebro, información relevante más el ruido eléctrico del resto de generadores que existen en el cuerpo, movimientos musculares, electrocardiograma, artefactos, etc. así como el ruido generado por los propios instrumentos de medida. Las señales resultantes son extremadamente pequeñas y complejas con amplitudes, en

# CLASIFICACION DE SEÑALES DE ELECTROENCEFALOGRAMA PARA DIAGNOSTICAR DEPRESION

torno a los 300µV (millonésimas de volt). Es indispensable, como consecuencia, una fase de pre-procesamiento de la señal EEG.

## 2.2 Análisis: Extracción de características usando análisis de componentes principales (PCA)

Análisis de componentes principales (PCA) es un método bien establecido para la reducción de extracción y dimensionalidad característica. En el PCA, se busca representar los datos de un espacio con dimensión  $d$  en un espacio de dimensiones inferiores. Esto reducirá los grados de libertad y reducirá la complejidad de espacio y tiempo.

El enfoque básico en PCA es el siguiente. Primero, el vector promedio  $\mu$  de dimensión  $d$  y la matriz de covarianza  $\Sigma$  con dimensión  $d \times d$  son calculados para el conjunto completo de datos. A continuación los vectores propios y valores propios son calculados y posteriormente los valores propios son ordenados en orden decreciente. Sean los vectores propios  $e_1$  con valor propio  $k_1$ , vector propio  $e_2$  con valor propio  $k_2$  y así sucesivamente. Subsecuentemente el valor  $k$  más grande de los vectores propios es elegido. En la práctica, esto se hace al observar el espectro de vectores propios<sup>12</sup>. A menudo la dimensión inherente es la del subespacio de la "señal". Las otras dimensiones son ruido. Forman una matriz de  $k \times k$  cuyas columnas consisten los  $k$  vectores propios. Preprocesar los datos según:

$$x^t = A^t(x - \mu) \quad (1)$$

Esta representación minimiza el criterio de error cuadrático<sup>13</sup>.

Tabla de datos		Componentes
$\begin{bmatrix} X_{11} & \dots & X_{1p} \\ \vdots & \ddots & \vdots \\ X_{n1} & \dots & X_{np} \end{bmatrix}$	$\rightarrow$	$\begin{bmatrix} C_{11} & \dots & C_{1p} \\ \vdots & \ddots & \vdots \\ C_{n1} & \dots & C_{np} \end{bmatrix}$
100% de la información		80%      0.002%

## 2.3 Características del método de clasificación: Análisis discriminante lineal (LDA)

La fórmula general para LDA se expone a continuación:

$$g(x) = W^t + w_0 \quad (2)$$

Donde  $X$  es el vector de entrada,  $W = [w_1 \dots w_n]^t$  es el vector de peso y  $w_0$  es el valor de umbral. Ecuación (2) indica que un vector  $n$ -dimensional  $X$  se proyecta sobre un vector  $W$  y que la variable,  $y = W^t X$ , es proyectado en  $g$ -espacio unidimensional y clasificado  $c_1$  o  $c_2$ , dependiendo de si  $y < w_0$  y  $y > w_0$ . El procedimiento de diseño óptimo para un clasificador lineal es seleccionar  $W$  y  $w_0$  que da el error más pequeño en el  $g$ -espacio proyectado. Este clasificador

## CLASIFICACION DE SEÑALES DE ELECTROENCEFALOGRAMA PARA DIAGNOSTICAR DEPRESION

es un clasificador estadístico binario, que se basa en las matrices de dispersión entre y dentro de las clases. La dispersión dentro de la clase,  $S_W$ , se describe como sigue:

$$S_i = \sum_{x \in c_i} (\bar{x} - \bar{m}_i)(\bar{x} - \bar{m}_i)^t \quad (3)$$

$$S_W = S_1 + S_2 \quad (4)$$

Donde  $S_i$  es la matriz de dispersión para la clase  $i$ . La dispersión entre clases,  $S_B$ , se calcula como sigue:

$$S_B = (\bar{m}_1 - \bar{m}_2)(\bar{m}_1 - \bar{m}_2)^t \quad (5)$$

Donde  $m_1$  y  $m_2$  son la media de la clase  $c_1$  y  $c_2$ . Las ponderaciones de este clasificador se optimizan basadas en el criterio de Fisher. Estas ponderaciones tratan de maximizar la dispersión entre clases y minimizar la dispersión dentro de las clases para hacer una mejor discriminación. Por último, los pesos óptimos se calculan como sigue:

$$W = S_W^{-1}(\bar{m}_1 - \bar{m}_2) \quad (6)$$

Donde  $S_W^{-1}$  es el inverso de la dispersión de clase dentro y  $m_1$  y  $m_2$  son la media de la clase  $c_1$  y  $c_2$ <sup>14-15</sup>.

El LDA puede considerarse como una técnica de reducción excesiva de dimensión de datos que comprime los predictores de dimensión  $p$ , en una dimensión. Al final del proceso se espera que cada clase tenga una distribución normal para las puntuaciones discriminantes pero con la diferencia más grande posible en las puntuaciones para las medias de las clases. Por lo que, el grado de traslape entre las puntuaciones discriminantes de las distribuciones puede utilizarse como una medida del éxito de la técnica. Las puntuaciones discriminantes se calculan mediante una función discriminante que tiene la forma:

$$D = w_1Z_1 + w_2Z_2 + w_3Z_3 + \dots + w_pZ_p \quad (7)$$

Como resultado una calificación discriminante es una combinación lineal ponderada de los predictores<sup>16</sup>.

### 3. RESULTADOS

En el estudio se tomaron 23 sujetos para realizar un pronóstico del diagnóstico. Se registraron 19 variables clasificadoras, correspondientes a los 19 canales del EEG, existen dos grupos a discriminar (sano y con depresión), se tomaron segmentos para el análisis de 512 puntos (2.56 segundos). Se consideran 14 sujetos que padecen depresión y 9 sujetos sanos.

## CLASIFICACION DE SEÑALES DE ELECTROENCEFALOGRAMA PARA DIAGNOSTICAR DEPRESION

La dimensión del EEG fue reducida usando PCA. Se usó el método de clasificación LDA teniendo como datos de entrada los componentes. Se comprobó el pronóstico del clasificador LDA con el diagnostico hecho por el medico experto obteniendo un valor alto de concordancia.

### 3.1 Extracción de características: PCA

Se realizó el análisis de componentes de cada uno de los sujetos para con todas las variables. Las pruebas intermedias del PCA que se ejecutaron son; Las pruebas resultaron significativas (Kaiser-Meyer-Olkin, Bartlett, Comunalidades y Varianza total explicada) y se muestra la tabla con el resumen de los componentes finales.

Tabla 1. Resumen de los sujetos con sus componentes principales, número de componentes y diagnóstico

n	Comp1	Comp2	Comp3	Comp4	NumComp	Tx
1	9.288	2.053	1.565	1.039	4	1
2	8.634	5.148	1.403	1.063	4	2
3	10.496	3.839	1.557	0.777	3	2
4	8.191	3.841	1.702	1.398	4	2
5	8.326	2.729	1.842	1.274	4	1
6	9.67	3.594	1.951	1.119	4	1
7	10.316	3.093	1.455	1.07	4	1
8	13.471	2.4	0.949	0.545		1
9	9.913	4.296	1.767	0.752	3	2
10	9.505	3.667	1.845	0.843	3	2
11	13.455	2.783	0.645	0.499	4	1
12	9.956	3.972	1.406	0.775	3	2
13	9.29	1.891	1.791	1.082	4	1
14	11.337	2.786	1.537	1.039	4	1
15	9.724	3.679	2.052	0.949	3	2
16	7.315	5.849	1.851	0.714	3	2
17	7.067	4.556	2.129	1.206	4	2
18	9.458	3.007	1.453	1.012	4	2
19	9.571	3.58	1.505	0.986	3	2
20	10.979	3.046	2.024	0.884	3	2
21	8.362	4.439	1.291	0.991	3	2
22	9.093	2.474	1.558	1.179	5	2
23	13.004	2.623	1.467	1.096	4	1

Nomenclatura: Comp<sup>n</sup> = enésimo componente

NumComp = número de componentes

Tx = Diagnostico

Nomenclatura: Comp<sup>n</sup> = enésimo componente

NumComp = número de componentes

Tx = Diagnostico

# CLASIFICACION DE SEÑALES DE ELECTROENCEFALOGRAMA PARA DIAGNOSTICAR DEPRESION

## 3.2 Clasificación: LDA

### 3.2.1. Prueba de igualdad de medias

La prueba de igualdad de medias, lambda de Wilks, demuestra que considerando las variables explicativas de forma individual, los valores de significancia son menores al 5% para algunas variables, por lo que, componente1, componente2 y número de componentes resultan significativos y muestran un poder discriminante, esto corrobora que es aplicable un análisis discriminante.

Tabla 2. Pruebas de igualdad de las medias de los grupos

	Lambda de Wilks	F	gl1	gl2	Sig.
Comp1	0.797	5.079	1	20	0.036
Comp2	0.597	13.511	1	20	0.001
Comp3	0.948	1.104	1	20	0.306
Comp4	0.979	0.437	1	20	0.516
NumComp	0.766	6.124	1	20	0.022

### 3.2.2. Prueba test M de Box

Aunque en el análisis discriminante es importante (aunque no necesario) que las matrices de covarianza poblacionales sean distintas, hay que tener en cuenta que el no cumplir con la prueba M de box es especialmente sensible en muestras grandes y en desviaciones de la normalidad multivariante de alguna variable.

Tabla 3. Test M de Box

Resultados de la prueba	
M de box	1.866
Aprox.	1.768
gl1	1
gl2	936.676
Sig.	0.184

Para el caso en cuestión las matrices de varianzas-covarianzas no son diferentes. En el análisis discriminante es importante que las matrices de covarianza poblacionales sean distintas. Conviene, no obstante, contrastar la igualdad de matrices de covarianzas, ya que no necesariamente el no cumplir con lo anterior tenga importancia en la vida práctica y real<sup>17</sup>.

## CLASIFICACION DE SEÑALES DE ELECTROENCEFALOGRAMA PARA DIAGNOSTICAR DEPRESION

### 3.2.3. Funciones canónicas discriminantes

Dados los valores del autovalor y la correlación canónica se concluye que existe una única función discriminante que permite de forma significativa (sig. 0.002) clasificar los sujetos en los dos grupos, sano y con depresión.

El valor de Wilks (0.597) nos ayuda a concluir que aunque la función discriminante servirá para pronosticar la pertenencia a los grupos, no todas las variables son discriminantes. Y dado que hay una cierta similitud entre los grupos y es importante estudiar la influencia de cada una de las variables en la función discriminante obtenida. En consecuencia se empleó el "método de inclusión por pasos" para, eliminar las no significativas en la función.

Tabla 4. Autovalores

Función	Autovalor	% de varianza	Correlación canónica
1	0.676	100	0.635

a. Se han empleado las 1 primeras funciones discriminantes canónicas en el análisis

Tabla 5 . Lambda de Wilks

Contraste de las funciones	Lambda de Wilks	Chi-cuadrado	gl	Sig.
1	0.597	10.065	1	0.002

### 3.2.4. Construcción de la función discriminante, estadísticos por pasos

Se indican las tablas 6, 7 y 8 que indican los pasos seguidos para la construcción de la función y consecuentemente que variables independientes son significativas para el modelo.

Para el caso solo se incluye el componente 2, de los comentarios al pie de la tabla de la primera tabla nos indican que se ha utilizado el valor de  $\lambda$  de Wilks global, el estadístico F para incorporar variables (criterio de entrada) y como estadístico para excluir variables (criterio de salida), y que el nivel de F ha sido insuficiente para continuar los cálculos, de lo que se concluye que no se han incluido todas las variables definidas para el análisis.

El contraste de la lambda de Wilks, si el p-valor es inferior a 0.05, implica a aceptar que existen diferencias de comportamiento entre las medias de los grupos. Por ello, el proceso realiza el test con todas las funciones para, a continuación, ir distribuyendo en dos tablas las variables seleccionadas de las que no lo son.

# CLASIFICACION DE SEÑALES DE ELECTROENCEFALOGRAMA PARA DIAGNOSTICAR DEPRESION

Tabla 6. Variables introducidas/excluidas <sup>a,b,c,d</sup>

Paso	Introducida	Lambda de Wilks							
		Estadístico	gl1	gl2	gl3	Estadístico	F exacta		Sig.
1	Comp2	0.597	1	1	2	13.511	1	2	0.001

En cada paso se introduce la variable que minimiza la lambda de Wilks global.

a. El número máximo de pasos es 10.

b. La F parcial mínima para entrar es 3.84.

c. La F parcial máxima para salir es 2.71

d. El nivel de F, la tolerancia o el VIN son insuficientes para continuar los cálculos.

Tabla 7. Variables en el análisis

Pasos	Tolerancia	F para salir
1	Comp2	13.511

Tabla 8. Variables no incluidas en el análisis

Paso	Tolerancia	Tolerancia min	F para entrar	Lambda de Wilks
Comp1	1	1	5.079	0.797
Comp2	1	1	13.511	0.597
Comp3	1	1	1.104	0.948
Comp4	1	1	0.437	0.979
NumComp	1	1	6.124	0.766
Comp1	0.906	0.906	0.795	0.573
Comp3	0.999	0.999	0.491	0.582
Comp4	0.97	0.97	0	0.597
NumComp	0.923	0.923	1.301	0.559

### 3.2.5. Estadísticos de clasificación

Tabla 9. Coeficientes de la función de clasificación

Contraste de las funciones	Lambda de Wilks	Chi-cuadrado
Comp2	4.485	6.586
Constante	-7.052	-13.482

*Funciones discriminantes lineales de Fisher*

*Funciones discriminantes lineales de Fisher*

## CLASIFICACION DE SEÑALES DE ELECTROENCEFALOGRAMA PARA DIAGNOSTICAR DEPRESION

Teniendo en cuenta que sí existen diferencias significativas entre las dos poblaciones estudiadas y que las variables seleccionadas tienen impacto en esas diferencias, se construyó una función discriminante,  $D$ , para estas poblaciones (sano y con depresión). Analizando los coeficientes de la función, se pueden hacer las siguientes inferencias sobre la relación de las variables utilizadas con las poblaciones estudiadas: el componente 2 se encuentra más relacionado con la población de sujetos sanos y que no hay variable asociada con el grupo de paciente con depresión.

Utilizando los valores obtenidos en la tabla 11 de los coeficientes para la función canónica discriminante, podemos construir la función,  $D$ , como:  $D = -7.052 + 4.485 \text{ Comp}2$

La correlación canónica de 0.635, tabla 4, indica que en promedio, de cada 100 sujetos que son clasificados con la función discriminante construida, entre 67 y 68 de estos serán clasificados correctamente, lo cual es aceptable ya que se puede decir que la regla es confiable.

La lambda de Wilks, tabla 5, nos da una idea de que tanto, nuestra regla discriminante, puede realmente discriminar entre las dos poblaciones de estudio; entre más cercano a cero, más poder de discriminación. Nuestro valor de 0,597 indica que nuestra función discriminante sí es válida. Otro indicador de esto es el p-valor, el cual debe ser menor a 0,05 para que exista evidencia estadística de que nuestra función es válida. Como se observa, nuestra función tiene un p-valor igual a 0.002. La tabla 12 presenta el resumen de esta clasificación:

Tabla 10. Resultados de la clasificación

	Tx	Grupo de Pertenencia		Total
		1	2	
Recuento	1	7	2	9
	2	3	11	14
Original	1	77.8	22.2	100
	2	21.4	78.6	100

a. Clasificados correctamente el 78.3% de los casos agrupados originales

# **CLASIFICACION DE SEÑALES DE ELECTROENCEFALOGRAMA PARA DIAGNOSTICAR DEPRESION**

## **4. CONCLUSIONES**

Diagnosticar a un paciente con depresión es una tarea conjunta de observar el EEG así como su historia clínica. Un clasificador PCA-LDA determina si presenta depresión o no y proporciona una herramienta valiosa a la hora del diagnóstico realizado por el especialista.

En este trabajo, para las señales de EEG se extraen características estadísticas por medio de PCA-SVD, se extrajeron características estadísticamente fundamentales, valores singulares, que fueron usados para definir un patrón de un paciente. La reducción de dimensión con el PCA mejora el desempeño del LDA. El resultado de la clasificación del EEG es prometedor y una aplicación alterna es un sistema de diagnóstico automático. La técnica de LDA muestra que con una buena caracterización de la señal de EEG y reduciendo los errores externos es una técnica de clasificación comparable en eficiencia con varias técnicas empleadas en el área de inteligencia artificial, que presentan un desempeño similar o ligeramente superior como maquinas con soporte vectorial (SVM), análisis discriminante cuadrático (QDA), k-vecino más cercano (KNN) entre otros. Los resultados obtenidos de una eficiencia del 80%, tabla 12, es alentador y se pretende optimizar el vector característico del EEG para aumentar esta eficiencia.

## **AGRADECIMIENTOS**

Al Dr. David Herrera Sánchez técnico especialista en electroencefalografía y al Dr. Moisés Álvarez Rueda con especialidad en psiquiatría.

## **RESPONSABILIDADES ÉTICAS PROTECCIÓN DE PERSONAS**

Los autores declaran que los procedimientos seguidos se conformaron a las normas éticas del comité de experimentación humana responsable y de acuerdo con la Asociación Médica Mundial y la Declaración de Helsinki.

## **CONFIDENCIALIDAD DE LOS DATOS**

Los autores declaran que han seguido los protocolos de su centro de trabajo sobre la publicación de datos de pacientes y que todos los pacientes incluidos en el estudio han recibido información suficiente y han dado su consentimiento informado por escrito para participar en dicho estudio.

## **DERECHO A LA PRIVACIDAD Y CONSENTIMIENTO INFORMADO**

Los autores han obtenido el consentimiento informado de los pacientes y/o sujetos referidos en el artículo. Este documento obra en poder del autor de correspondencia.

# CLASIFICACION DE SEÑALES DE ELECTROENCEFALOGRAMA PARA DIAGNOSTICAR DEPRESION

## CONFLICTO DE INTERESES

Los autores declaran no tener ningún conflicto de intereses

## BIBLIOGRAFÍA

1. Berger H. Über das Elektroencephalogram des Menschen. Arch. f. Psychiat. 1929; 87: 527-70.
2. Bronzino J.D. Principles of electroencephalography. J.D. Bronzino (Ed.), The biomedical engineering handbook (2nd ed.) CRC Press LLC, Boca Raton (2000)
3. Kaye, J., Morton, J., Bowcutt, M., & Maupin, D. Depression: The forgotten diagnosis among hospitalized adults. Journal of Neuroscience Nursing. 2000; 32(1): p. 9-16.
4. Organização Pan-Americana da Saúde. Organização Mundial da Saúde. Relatório Sobre A Saúde No Mundo 2001: Saúde Mental: Nova Conceção, Nova Esperança. Genebra; 2001
5. Subasi A. Automatic detection of epileptic seizure using dynamic fuzzy neural networks. Expert Systems with Applications. 2006; 31: p. 320–328.
6. Cao LJ, Chua KS, Chong WK, Lee HP, Gu QM. A comparison of PCA, KPCA and ICA for dimensionality reduction in support vector machine. Neurocomputing. 2003; 55: pp. 321–336.
7. Subsi A, Gursoy MI. EEG signal classification using PCA, ICA, LDA and support vector machines. Expert Systems with Applications. 2010; 37, 12: p. 8659–8666.
8. AEEGS. American Electroencephalographic Society guidelines for standard electrode position nomenclature. J Clin Neurophysiol. 1991; 8:200–202.
9. Towle VLV, Bolaños J, Suarez D, Tan K, Grzeszczuk R, Levin N D. et al. The spatial location of EEG electrodes: locating the best-fitting sphere relative to cortical anatomy. Electroencephalography and Clinical Neurophysiology. 1993; 86, 1: p. 1–6.
10. American Psychiatric Association [APA]. Diagnostic and statistical manual of mental disorders. 4th. ed. Washington DC: APA. 1994.
11. Organización Mundial de la Salud. Clasificación estadística internacional de enfermedades y problemas relacionados con la salud. Rev. v.3. Washington, D.C. OPS. 1995.
12. Lotte F, Congedo M, Lécuyer A, Lamarche F, Arnaldi B. A review of classification algorithms for EEG-based brain-computer interfaces. J. Neural Eng. 2007; 4, 2: R1-R13.
13. Parra LC, Spence CD, Gerson AD, Sajda P. Recipes for the linear analysis of EEG. NeuroImage. 2005; 28: p. 326 – 341.
14. Acharya UR, Sree SV, Chuan-Alvina AP, Suri JS. Use of principal component analysis for automatic classification of epileptic EEG activities in wavelet framework. Expert Systems with Applications. 2012; 39, 10: p. 9072–9078.

## **CLASIFICACION DE SEÑALES DE ELECTROENCEFALOGRAMA PARA DIAGNOSTICAR DEPRESION**

15. Sabeti M, Katebi SD, Boostani R, Price GW. A new approach for EEG signal classification of schizophrenic and control participants. *Expert Systems with Applications*. 2011; 38, 3: p. 2063–2071.
16. Lehmann C, Koenig T, Jelic V, Prichet L, John RE., Wahlund LO et al. Application and comparison of classification algorithms for recognition of Alzheimer's disease in electrical brain activity (EEG). *Journal of Neuroscience Methods*. 2007; 161, 2: p. 342–350.
17. Rodriguez-Siek KE, Giddings CW, Doetkott C, Johnson TJ, Fakhr MK, Nolan LK. Comparison of *Escherichia coli* isolates implicated in human urinary tract infection and avian colibacillosis. *Microbiology*. 2005; 151: p. 2097–2110.