

# Máquinas de aprendizaje para clasificar señales electroencefalográficas

## Machine learning for classifying electroencephalographic signals

Naive Angulo H., Lic., Jose Sanz, MSc., Victor Malavé G., Msc., Mireya Barrera A., MSc., Heriberto Spinetti, Lic. y Pablo Guillén, PhD.

Universidad de los Andes, Venezuela

angulonaiven@ula.ve, jmsanz@cantv.net, vicmal@cantv.net, mirebar@ula.ve, heriberto\_Spinetti@ula.ve, pguillen@ula.ve

Recibido para revisión 28 de mayo de 2009, aceptado 10 junio de 2009, versión final 20 junio de 2009

**Resumen**—Entre las múltiples técnicas computacionales que existen para conducir tareas de clasificación de datos, las máquinas de aprendizaje como las máquinas de soporte vectorial (SVM, por sus siglas en inglés) se destacan por mostrar altos niveles de eficiencia. En este trabajo se aplica un enfoque metodológico particular orientado a la discriminación de una condición patológica a partir de un conjunto de datos que representan señales electroencefalográficas (EEG), utilizando para ello la función svm de la biblioteca e1071 implantada en el programa estadístico R. La base de datos usada para el entrenamiento y validación de la SVM está constituida por un conjunto de señales EEG correspondientes a 10 sujetos sanos y 10 pacientes epilépticos (entre los que se encuentra un registro antes y durante una crisis convulsiva registrada accidentalmente en la consulta). Previo al proceso de clasificación, se aplica una técnica de la minería de datos llamada parámetros de sincronización, la cual transforma las señales EEG a unos índices estadísticos que extraen patrones e información oculta inherente en las señales. Una vez obtenidos los parámetros de sincronización, parte de éstos se emplearon para el entrenamiento y el resto para la validación de la SVM. Una eficiencia del 99% de clasificación entre sujetos sanos y pacientes epilépticos es obtenida con la metodología presentada.

**Palabras Clave**—Sistemas Inteligentes, Máquinas de Aprendizaje, Minería de Datos, Electroencefalografía, Epilepsia.

**Abstract**—Along the many computational techniques that exist for driving tasks data classification, machine learning and support vector machines (SVM) are notorious for displaying high levels of efficiency. This paper applies a methodological approach aimed at including the discrimination of a pathological condition based on a set of data

representing signals electroencephalographic (EEG), using the SVM function of the library e1071 installed in the statistical program R. The database used for training and validation of the SVM consists of a set of EEG signals of 10 healthy subjects and 10 epileptic patients (including one record before and during a seizure recorded accidentally in the laboratory). Pre-classification process, applies a technique called data mining synchronization parameters, which processes the EEG signals to extract some statistical patterns and hidden information inherent in the signals. Once obtained the synchronization parameters, some of them were used for training and the remainder for the validation of the SVM. An efficiency rating of 99% among healthy subjects and epileptic patients is obtained with the methodology presented.

**Keywords**—Intelligent Systems, Machine Learning, Data Mining, Electroencephalography, Epilepsy.

### I. INTRODUCCIÓN

En la actualidad la minería de datos representa un recurso importante en el procesamiento de datos, con ello se logra identificar patrones y relaciones ocultas en los datos los cuales permiten la creación de modelos que ayudan a un mejor entendimiento y diagnóstico de ciertas patologías como la epilepsia. Uno de los avances de la minería de datos es el análisis computarizado de las señales electroencefalográficas (EEG), éste permite caracterizar los desordenes de la actividad cerebral a través de la información oculta contenida en las señales EEG de pacientes epilépticos [3-4]. La epilepsia es descrita a nivel fisiológico como la descarga sincronizada de impulsos eléctricos entre las neuronas de la corteza cerebral. Las diversas interconexiones entre neuronas dentro de áreas cercanas y distantes de la corteza, reflejan la complejidad del procesamiento

serial y paralelo de la información sensorial y motora recibida en el cerebro. Sin embargo, dichas conexiones resultan en descargas sincrónicas en grandes grupos de neuronas. Durante estas interacciones sincronizadas un ataque epiléptico se manifiesta, el cual tiene serias consecuencias en el comportamiento del individuo que padece esta patología. Estas descargas anormales pueden ocurrir en regiones locales del cerebro, fenómeno conocido como ataques o crisis parciales o focales. Dichas descargas se ven solamente en algunos canales del registro electroencefalográfico, en otros casos, las descargas abarcan todo el cerebro (crisis generalizadas), actividad que se observa en todos los canales del EEG [6].

El uso de modelos matemáticos permite representar la no linealidad del EEG con la intención de describir y comprender los procesos fisiológicos de la dinámica de un cerebro normal o patológico [2]. Diferentes técnicas del análisis no lineal han sido aplicadas para tratar de describir estos fenómenos [2]. Una herramienta valiosa para modelar y clasificar los procesos fisiológicos son las máquinas de soporte vectorial, SVM [7].

En este trabajo se hace uso de la función SVM de la biblioteca e1071 implantada en el programa estadístico R [9], con el objetivo de clasificar señales EEG correspondientes a 10 sujetos sanos y 10 pacientes epilépticos. Previo al proceso de clasificación, se hace uso de una técnica de la minería de datos llamada parámetros de sincronización, la cual consiste en transformar las señales EEG en unos índices estadísticos (parámetros) los cuales permiten cuantificar el grado de sincronización de la actividad cerebral. Obtenidos estos parámetros, se usa parte de ellos para el entrenamiento y el resto para la validación de la SVM. Una eficiencia del 99% se obtiene en la clasificación de sujetos sanos y pacientes epilépticos con las técnicas presentadas.

## II. MATERIALES Y METODOS

### A. Análisis Electroencefalográfico de la Epilepsia

El análisis electroencefalográfico está basado principalmente en la exploración y reconocimiento de patrones gráficos en series temporales no estacionarias llamadas registros electroencefalográficos. El electroencefalograma (EEG) es un registro de los potenciales eléctricos (medidos en  $\mu$ V) generados por las células nerviosas de la corteza cerebral. Existen dos tipos de EEG dependiendo de donde sea tomada la señal eléctrica en la cabeza: el EEG de superficie o el EEG intracraveal. El EEG de superficie es registrado a través de electrodos en forma de discos colocados en el cuero cabelludo del individuo, manteniendo un buen contacto mecánico y eléctrico con el mismo. El EEG intracraveal es registrado a través de electrodos especiales colocados directamente en la corteza cerebral durante una cirugía a cráneo abierto, por lo que también se le denomina Electrocorticograma. Para poder obtener un registro exitoso de la actividad cerebral los electrodos deben poseer una

impedancia menor a 5 kHz. Los cambios de voltaje entre los electrodos colocados en los diferentes canales de registro, regidos por el sistema internacional 10-20, ver figura 1, [6], son medidos y amplificados antes de ser enviados a algún dispositivo de registro y muestra, como puede ser un computador con un software diseñado para este propósito. El EEG registrado muestra la distribución en el tiempo de las amplitudes de los potenciales eléctricos registrados en el cuero cabelludo del individuo. La inspección clínica visual de un EEG incluye el examen de los siguientes parámetros: frecuencia o longitud de onda, voltaje o amplitud, regularidad de la forma de onda, reacción ante estímulos ópticos e hiperventilación (respiración acelerada). También incluye la identificación del rango espacial (local o generalizado, unilateral o bilateral) y la persistencia temporal (esporádica y breve o prolongada y persistente) de las anomalías relacionadas con diferentes patologías.

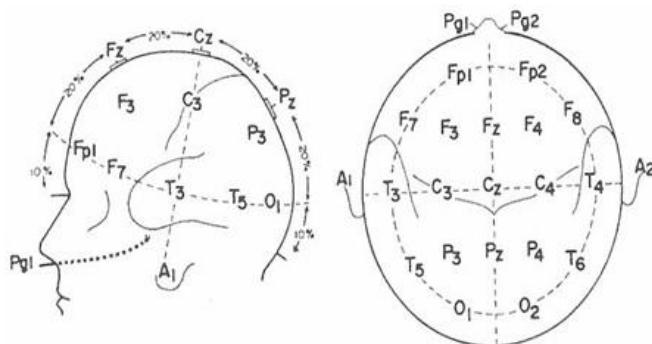


Figura 1. Sistema Internacional 10-20.

El EEG contiene un amplio rango de frecuencias, pero el rango de componentes de interés clínico y fisiológico se encuentra entre 0.3 Hz y 30 Hz. Este a su vez es dividido aproximadamente en distintas bandas de frecuencia de la siguiente manera [3, 4, 5, 6]:

- Delta (<4 Hz): Los ritmos delta son ondas lentas preponderantes en etapas de sueño profundo en adultos. De otra manera sugieren la presencia de patologías.
- Theta (4-8 Hz): Esta banda de frecuencias aparece en infantes normales y niños, así como también, en el sueño de los adultos. Sólo una pequeña cantidad de ondas theta aparecen en los adultos despiertos. La presencia de una gran cantidad de ondas theta en adultos despiertos sugiere condiciones anormales y patológicas.
- Alfa (8-13 Hz): Los ritmos alfa aparecen en adultos normales durante estados de relajación e inactividad mental cuando se encuentran despiertos. La amplitud del ritmo es por lo general menor a 50  $\mu$ V, éste aparece prominentemente en la región occipital. El ritmo alfa es bloqueado al abrir los ojos

(atención visual) o al realizar otros esfuerzos mentales como pensar.

- Beta (14-30 Hz): Este ritmo se presenta en la región frontocentral, con menor amplitud que alfa. Las ondas beta aumenta en estados de expectativa y tensión.
- Gamma (>30 Hz): Los ritmos gamma poseen una banda de altas frecuencias y por lo general no representan fenómenos de naturaleza clínica, sino más bien, psicofisiológica. Normalmente son descartados del registro electroencefalográfico clínico convencional.

## B. Base de Datos

### Obtención y Procesado de las Señales EEG

El registro de las señales EEG se realizó en 19 canales a partir de electrodos adheridos a la superficie de la cabeza con pasta conductora, en los sitios establecidos por el sistema internacional 10-20, midiéndose la diferencia de potencial respecto a una referencia constituida por ambas orejas cortocircuitadas. Se digitalizó la señal a una frecuencia de muestreo de 256 Hz y conversión A/D de 12 bits, filtrada digitalmente entre 0.5 y 30 Hz. Se seleccionaron para el análisis, registros de tiempo variable de actividad en reposo de 10 sujetos sanos y 10 pacientes epilépticos (entre los que se encuentra un registro antes y durante una crisis convulsiva, registrada accidentalmente en la consulta). En la figura 2 se muestra el canal O1-Ref del EEG de un sujeto sano y en la figura 3 se muestra el canal O1 Ref del EEG de un paciente epiléptico antes y durante una crisis convulsiva. Para el análisis de la señal del paciente epiléptico durante la crisis convulsiva se excluyen las zonas donde el amplificador se satura. La base de datos pertenece al Laboratorio de Electrofisiología del Hospital San Juan de Dios, Mérida, Venezuela.

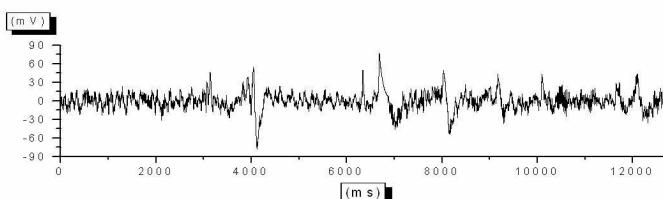


Figura 2. Canal O1-Ref de un registro EEG de un sujeto sano.

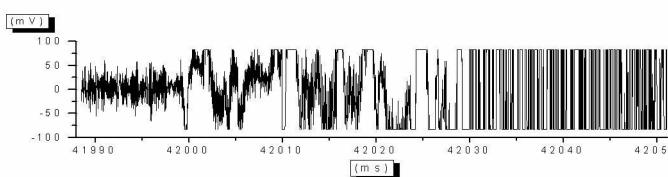


Figura 3. Canal O1-Ref de un registro EEG de un paciente antes y durante una crisis epiléptica.

## C. Métodos

### 1) Parámetros de Sincronización

Estudio de la Formación de Clusters: Se define un dominio dinámico o cluster, como un subconjunto de la población de la serie temporal, tal que, las distancias en pares de elementos distintos, pertenecientes a este subconjunto, sean menor que un cierto valor umbral  $\gamma$ , esto es,  $d_{ij} < \gamma$ . La formación de dominios dinámicos puede ser caracterizada por la frecuencia de distancias en pares entre elementos, la cual se define como

$$d_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2 + (z_i - z_j)^2} \quad (1)$$

Parámetros de Orden  $r(t)$  y  $s(t)$ : Cercano al punto de formación de clusters, llamado también transición de condensación [8], sólo una pequeña fracción de elementos se encuentran formando clusters, mientras que el resto de los elementos se encuentran dispersos entre sí. Para medir la extensión de la formación de dominios dinámicos, se introducen dos parámetros de orden [1,8]. El primero de ellos,  $r(t)$ , está dado por la fracción de pares de elementos  $(i,j)$  que en un tiempo  $t$  están separados una distancia  $d_{ij} < \gamma$ :

$$r(t) = \frac{1}{N(N-1)} \sum_{i=1}^N \sum_{j=1}^N \Theta[\gamma - d_{ij}(t)] \quad (2)$$

donde  $\Theta(x)$  es la función Heaviside, tal que  $\Theta(x)=0$  para  $x < 0$  y  $\Theta(x)=1$  en caso contrario. El segundo parámetro de orden,  $s(t)$ , es la fracción de elementos  $i$  que en un tiempo  $t$  tienen al menos un elemento  $j$  localizado a una distancia  $d_{ij} < \gamma$ :

$$s(t) = 1 - \frac{1}{N} \sum_{i=1}^N \prod_{j=1; j \neq i}^N \Theta[d_{ij} - \gamma] \quad (3)$$

El último término de la ecuación (3) es la fracción de elementos que no tienen ningún otro elemento dentro de una esfera de radio  $\gamma$ . Cuando la sincronización es total,  $r(t)=s(t)=1$ . Si toda la población de osciladores está formando clusters se tiene  $s(t)=1$ , mientras que  $r(t)<1$ , debido a que las distancias pueden aún ser muy grandes [1, 8]. Finalmente, si algunos de los elementos están formando clusters pero otros están libres, encontramos  $r(t)<s(t)<1$ .

### 2) Máquinas de Soporte Vectorial

La teoría de las máquinas de Soporte vectorial (Support Vector Machine, SVM por sus siglas en inglés) fue desarrollada por Vapnik basado en la idea de minimización del riesgo estructural

(principio inductivo SRM). Primero, la SVM mapea los puntos de entrada a un espacio de características de una dimensión mayor (ejemplo, si los puntos de entrada están en  $R^2$  entonces serán mapeados a  $R^3$  por la SVM), para luego encontrar el hiperplano que los separe y maximice el margen  $m$  entre las clases, ver figura 4.

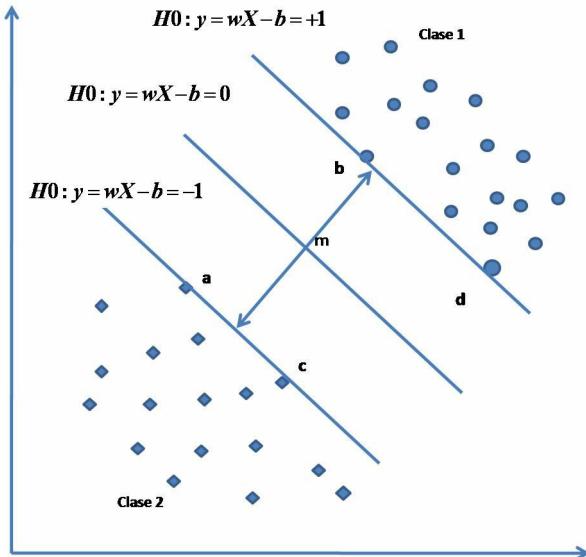


Figura 4. Maximización del margen  $m$

Al maximizar el margen  $m$ , la separación de las clases es un problema de programación cuadrática y puede ser resuelto por su problema dual introduciendo multiplicadores de Lagrange. La SVM puede encontrar el hiperplano óptimo utilizando el producto punto con funciones en el espacio de características que son los llamados kernels. Los vectores de soporte son combinaciones de unos pocos puntos de entrada que permite escribir la solución del hiperplano de manera más sencilla.

Consideré el caso de:

- Un conjunto de  $N$  puntos de datos de entrenamiento

$$\{(X_1, Y_1), \dots, (X_N, Y_N)\}$$

- Un hiperplano

$$H_0: y = wX - b = 0 \quad (4)$$

Donde  $w$  es normal al hiperplano,  $b/\|w\|$  es la distancia perpendicular al origen y  $\|w\|$  es la norma euclídea de  $w$

- Dos hiperplanos paralelos a  $H_0$ :

$$H_1: y = wX - b = +1 \quad (5)$$

$$H_2: y = wX - b = -1 \quad (6)$$

Con la condición que no hay puntos de datos entre  $H_1$  y  $H_2$ .

Esta situación es ilustrada en la figura 4. Si la distancia  $d_+(d_-)$  es la distancia más corta desde la separación del hiperplano  $H_0$  al punto más cercano positivo (negativo), donde el hiperplano  $H_1(H_2)$  está ubicado, entonces la distancia entre los planos  $H_1$  y  $H_2$  es  $d_+ + d_-$ . Así  $d_+ = d_- = 1/\|w\|$ , entonces el margen es igual a  $2/\|w\|$ . El problema es encontrar el hiperplano que dé el máximo margen. Los parámetros  $w$  y  $b$  son llamados vector peso y sesgo, respectivamente. La optimización del problema se presenta con la ecuación:

$$\text{Min}_{w,b} \frac{1}{2} w^T w \text{ restringido por: } \gamma_i (wX - b) \geq 1 \quad (7)$$

La optimización del problema presentado en la ecuación anterior puede ser declarada en un problema convexo, cuadrático en  $(w,b)$  en un conjunto convexo. Usando la formulación del Lagrangiano, las limitaciones pueden ser reemplazadas por limitaciones de multiplicadores de Lagrange en sí mismos. Adicionalmente en esta reformulación, como una consecuencia de los datos de entrenamiento, podría solo aparecer en la forma producto punto entre los vectores de datos, introduciendo los multiplicadores de Lagrange  $\alpha_1, \dots, \alpha_N \geq 0$ , una función de Lagrange para la optimización del problema puede ser definida como:

$$L_p(w, b, \alpha) = \frac{1}{2} w^T w - \sum_i (\alpha_i \gamma_i (w \cdot X_i - b) - \alpha_i) \quad (8)$$

Usando la formulación dual y las limitaciones del problema de optimización de Lagrange, los parámetros  $\alpha_i$  pueden ser calculados y los parámetros  $w, b$  los cuales especifican la separación del hiperplano, pueden ser calculados usando las siguientes ecuaciones:

$$w = \sum \alpha_i \gamma_i X_i \quad (9)$$

$$\alpha_i (\gamma_i (w \cdot X_i + b) - 1) = 0, \forall i \quad (10)$$

De acuerdo a la ecuación (9), los parámetros  $\alpha_i$  que no son iguales a cero corresponden a la data  $X_i, Y_i$  que son los vectores de soporte a, b, c y d (ver figura 4)

Si la superficie de separación de dos clases no es lineal, los datos pueden ser transformados en otro espacio característico de dimensión más alta donde el problema es linealmente separable. Si la transformación a un espacio dimensional mayor es  $\phi()$  entonces la función Lagrangiana puede ser expresada como:

$$L_D = \sum_i a_i - \frac{1}{2} \sum_{i,j} a_i a_j \gamma_i \gamma_j \phi(X_i) \phi(X_j) \quad (11)$$

El producto punto  $\phi(X_i) \phi(X_j)$  en el que espacios de dimensión alta definen una función Kernel  $K(X_i, X_j)$  y por lo tanto esto no necesariamente explícito desde la transformación  $\phi()$  siempre y cuando se conozca la función kernel correspondiente al producto punto en el mismo espacio característico de dimensión alta.

Con un kernel adecuado, la SVM puede separar en el espacio característico los datos que en el espacio original de entrada no es separable. Hay muchas funciones kernel que puede ser utilizadas, por ejemplo:

$$K(X_i, X_j) = e^{-\|X_i - X_j\|^2 / 2\sigma^2} \quad (12)$$

(función kernel Gaussiana de base radial)

$$K(X_i, X_j) = (X_i \cdot X_j + m)^p \quad (13)$$

(kernel polinomial.)

Una función kernel tiene una buena eficiencia si los vectores de soporte calculados utilizando la correspondiente transformación son pocos y si la clasificación de la data de prueba es suficiente.

En resumen, con el fin de separar un conjunto de datos, un conjunto de data de entrenamiento ( $X, Y$ ) es seleccionado, el problema de optimización es resuelto y los parámetros  $\gamma_i, w, b$  son calculados. Entonces, un vector de datos  $X$  dado del conjunto de data inicial es clasificado de acuerdo al valor de  $(wX^* + b)$ . La eficiencia de los vectores de soporte calculados es probada usando el conjunto de la data de prueba derivados del conjunto de datos inicial.

### III. RESULTADOS

Se realizaron 7 ejecuciones sobre los datos constituidos por un conjunto de señales EEG correspondientes a 10 sujetos sanos y 10 pacientes epilépticos (entre los que se encuentra un registro antes y durante una crisis convulsiva registrada accidentalmente en la consulta). Las figuras 5 y 6 presentan una muestra representativa de los datos y la Tabla 1 muestra los mínimos, máximos y media de los datos transformados en los parámetros  $r(t)$  y  $s(t)$ .

El entrenamiento de la máquina de soporte vectorial se realiza mediante el programa e1071 del software R, usando la función `svm` para la construcción del modelo y los métodos: `predict` con

el cual se hace la predicción de la clasificación sobre el archivo de patrones conocidos, el método `tab` genera una tabla de validación cruzada con la que se observa el acierto del modelo en la predicción de la clasificación y el método `classAgreement` genera como resultado en valores relativos fácilmente extrapolables a valores porcentuales, el grado de eficiencia del modelo en la clasificación para un conjunto dado de valores.

La Tabla 2 presenta los resultados de predicción y clasificación de la máquina de soporte vectorial usando los datos obtenidos sobre los parámetros de orden  $r(t)$  y  $s(t)$ , el número de vectores de soporte que genera la SVM, la diagonal que indica el porcentaje de datos que se muestran en la diagonal de una tabla de contingencia bidimensional, en donde los renglones señalan las clasificaciones reales y las columnas de clasificación realizada por la máquina de soporte vectorial, finalmente  $Kappa$  señala una corrección probabilística del valor calculado para la diagonal, en el caso en que las clases no sean uniformes.

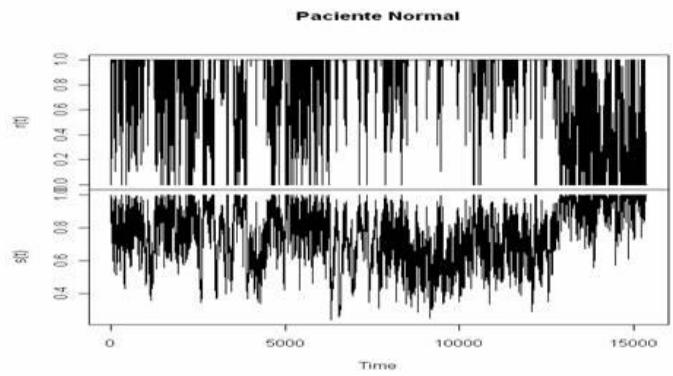


Figura 5. Muestra de un Sujeto Normal

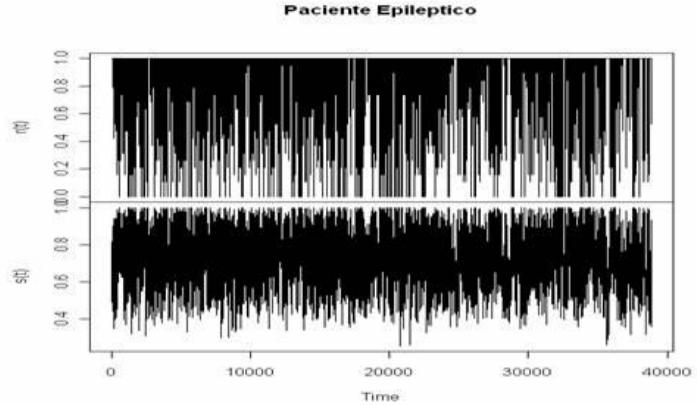


Figura 6. Muestra de un Paciente Epiléptico

		<b>s(t)</b>	<b>r(t)</b>
<b>Sujetos Sano</b>	<b>Min</b>	<b>0.4472</b>	<b>0.6571</b>
	<b>Mean</b>	<b>0.7765</b>	<b>0.7812</b>
	<b>máx.</b>	<b>0.9719</b>	<b>0.9085</b>
<b>Pacientes Epiléptico</b>	<b>Min</b>	<b>0.4640</b>	<b>0.6886</b>
	<b>Mean</b>	<b>0.8034</b>	<b>0.7489</b>
	<b>máx.</b>	<b>0.9178</b>	<b>0.8826</b>

Tabla 1. Valores representativos de los datos

		<b>Variables de rendimiento</b>		
		<b>Nº de vectores de soporte</b>	<b>Diagonal</b>	<b>Kappa</b>
<b>Corrida 1</b>	<b>Lineal</b>	<b>4752</b>	<b>0.995077</b>	<b>0.9899246</b>
	<b>Polinomial</b>	<b>5642</b>	<b>0.993067</b>	<b>0.9858263</b>
	<b>Radial</b>	<b>4867</b>	<b>0.99391</b>	<b>0.98753391</b>
<b>Corrida 2</b>	<b>Lineal</b>	<b>4689</b>	<b>0.994611</b>	<b>0.9889642</b>
	<b>Polinomial</b>	<b>5670</b>	<b>0.9939119</b>	<b>0.9875209</b>
	<b>Radial</b>	<b>4958</b>	<b>0.9950188</b>	<b>0.9898178</b>
<b>Corrida 3</b>	<b>Lineal</b>	<b>4295</b>	<b>0.993941</b>	<b>0.9879552</b>
	<b>Polinomial</b>	<b>5235</b>	<b>0.993941</b>	<b>0.988819</b>
	<b>Radial</b>	<b>4445</b>	<b>0.994378</b>	<b>0.988819</b>
<b>Corrida 4</b>	<b>Lineal</b>	<b>4187</b>	<b>0.994407</b>	<b>0.9888765</b>
	<b>Polinomial</b>	<b>5131</b>	<b>0.993737</b>	<b>0.9875524</b>
	<b>Radial</b>	<b>4395</b>	<b>0.994276</b>	<b>0.9886173</b>
<b>Corrida 5</b>	<b>Lineal</b>	<b>4158</b>	<b>0.994407</b>	<b>0.9888765</b>
	<b>Polinomial</b>	<b>5099</b>	<b>0.9936934</b>	<b>0.9874661</b>
	<b>Radial</b>	<b>4381</b>	<b>0.9942905</b>	<b>0.9886461</b>
<b>Corrida 6</b>	<b>Lineal</b>	<b>4175</b>	<b>0.9943925</b>	<b>0.9888477</b>
	<b>Polinomial</b>	<b>5101</b>	<b>0.9935186</b>	<b>0.987121</b>
	<b>Radial</b>	<b>4382</b>	<b>0.9942905</b>	<b>0.9886461</b>
<b>Corrida 7</b>	<b>Lineal</b>	<b>4172</b>	<b>0.9942323</b>	<b>0.988531</b>
	<b>Polinomial</b>	<b>5100</b>	<b>0.9935623</b>	<b>0.9872073</b>
	<b>Radial</b>	<b>4386</b>	<b>0.9942323</b>	<b>0.988531</b>

Tabla 2. Valores de rendimiento de la SVM

Estos resultados señalan que el kernel lineal genera un menor número de vectores de soporte en relación al kernel polinómico y al radial, por otro lado la eficiencia con cualquiera de los kernel no tiene diferencias significativas y en general la eficiencia de la SVM está por encima del 99%. Sin embargo, la alta eficiencia de los modelos utilizados resta la posibilidad de realizar el ejercicio de optimización de los parámetros de estos kernel.

#### IV. CONCLUSIONES

La técnica de parámetros de sincronización la cual cuantifica la actividad cerebral de sujetos sanos y pacientes epilépticos, captura información inherente de los registros EEG de manera que al ser utilizada en la máquina de soporte vectorial para el problema de clasificación permite la obtención de una eficiencia de aproximadamente 99%. Esta investigación confirma el uso de técnicas computacionales eficientes las cuales podrían ayudar a un mejor entendimiento de la patología epiléptica y su clasificación para un mejor diagnóstico médico.

#### REFERENCIAS

- [1] Escalona-Moran M., Cosenza M., Guillén P., Coutin P. Synchronization and clustering in electroencephalographic signals. Chaos, Solitons and Fractals, 2007, pp. 31, 820, 825
- [2] Guillén P., Coutin E., Coutin P., Arias S. Análisis de registros electroencefalográficos en pacientes epilépticos utilizando dinámica no lineal. IV Congreso Anual de Ingeniería ASME USB Caracas, Venezuela, 2005.
- [3] Kandel E., Schwartz J., Jessell T. Principles of Neural Science. Third Edition. Elsevier Science Publishing Co., Inc. New York, New York 10010, 1991, pp. 777-787.
- [4] Kellaway P. An orderly approach to visual analysis: characteristics of the normal EEG of adults and children. Daly D., Pedley T., editors. Current practice of clinical electroencephalography, 2nd ed. New York, NY: Raven Press, 1990, pp. 139-199.
- [5] Niedermeyer E. Historical aspects. In: Niedermeyer E., F. Silva, editors. Electroencephalography, basic principles, clinical applications, and related fields. Baltimore, Maryland: Williams & Wilkins, 1991, pp. 1-14.
- [6] NINDS (2001) Seizure and epilepsy: hope through research. National Institute of Neurological Disorders and Stroke. [http://www.ninds.nih.gov/health\\_and\\_medical/pubs/seizures\\_and\\_epilepsy\\_htr.htm](http://www.ninds.nih.gov/health_and_medical/pubs/seizures_and_epilepsy_htr.htm) Bethesda, MD.
- [7] Maglogiannis I., Zafiroopoulos E. Characterization of digital medical images utilizing support vector machines. BMC Medical Informatics and Decision Making. BioMed Central, 2004.
- [8] Manrubia S., A. S. Mikhailov. Phys. Rev. E, 1999, pp. 60- 1579.
- [9] Meyer D. Support Vector Machines. The Interface to libsvm in package e1071. Technische Universität Wien. Austria. October 21. 2007.