



BENEMÉRITA UNIVERSIDAD AUTÓNOMA DE PUEBLA  
FACULTAD DE CIENCIAS DE LA COMPUTACIÓN

---

## Clasificación de señales cerebrales

---

TESIS PROFESIONAL PARA OBTENER EL TÍTULO DE:  
MAESTRO EN CIENCIAS DE LA COMPUTACIÓN

**Lic. Arturo Cavazos Juárez**

*Asesor:*

Dr. Ivo Humberto Pineda Torres

*Co-asesor:*

Dra. María Josefa Somodevilla García



---

---

# Resumen

---

En la actualidad existen una inmensa cantidad de instrumentos médicos que permiten capturar las señales provenientes del cerebro, algunos de ellos son demasiado caros, lo cuál hace difícil el acceso al aparato. Por otro lado, el constante avance de la tecnología permite desarrollar sistemas más accesibles, la única desventaja, en ocasiones, es la limitante en la interfaz que manejan.

El objetivo principal de esta tesis es abordar la captura, visualización y análisis de las señales; para la captura, se utilizó una placa Arduino llamada "Spiker Shield", la cuál es de bajo coste. Para la visualización, se desarrolló una interfaz en lenguaje C#, misma que permite manipular las señales en un formato estándar para su representación. Por último, para el análisis, se recurre a métodos computacionales inspirados en aprendizaje automático.





# Agradecimientos

Agradezco a Dios por acompañarme y guiarme en cada momento de la vida, por ser mi fortaleza en los momentos de debilidad, por una vida llena de aprendizaje y experiencias únicas a lado de personas maravillosas.

Doy gracias a mis padres Gonzalo y Rosa por su apoyo incondicional desde niño, por los valores que han inculcado en mi, por las anécdotas de vida y motivación para seguir adelante. Sin duda alguna, mi ejemplo a seguir.

A mi hermano Gonzalo, quien es parte importante de mi vida, por los momentos alegres que juntos compartimos, por las incontables aventuras y risas de las mismas.

A Dulce, que en poco tiempo ha llegado a significar tanto, por su apoyo en las buenas y en las malas, por su paciencia y amor incondicional.

A mis compañeros de maestría, por hacer más llevaderos estos dos años, por la amistad que hemos llegado a tener y los momentos que hemos disfrutado, muchas gracias.

A mis asesores el Dr. Ivo y Dra. María Josefa, mi más sincero agradecimiento por su apoyo constante, a los doctores por compartir parte de sus conocimientos y experiencias a lo largo de mis estudios de maestría en la BUAP.

A la BUAP, por todas las facilidades proporcionadas durante mi estancia académica.

A CONACYT por el apoyo económico durante estos dos años.



---

---

# Índice general

---

<b>Índice general</b>	<b>I</b>
<b>Índice de figuras</b>	<b>III</b>
<b>Índice de tablas</b>	<b>IV</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Motivación . . . . .	1
1.2. Descripción del problema . . . . .	2
1.3. Objetivos de la Tesis . . . . .	3
1.4. Estructura de la Tesis . . . . .	3
<b>2. Estado del arte</b>	<b>5</b>
2.1. Electroencefalografía . . . . .	5
2.2. Tipos de onda en señales . . . . .	6
2.3. Enfermedades cerebrales . . . . .	7
2.3.1. Epilepsia . . . . .	7
2.4. Captar señal EEG . . . . .	8
2.4.1. Tipos de electrodos . . . . .	8
2.4.2. Sistema de posicionamiento de los electrodos . . . . .	10
2.5. Formato de Datos Europeo (EDF) . . . . .	12
2.5.1. Fórmulas utilizadas en EDF . . . . .	14
2.5.2. Uso de formato EDF . . . . .	14
2.6. Trabajo relacionado . . . . .	15
2.6.1. Ritmo de Berger . . . . .	15
2.6.2. Detección y clasificación de enfermedades cerebrales . . . . .	16
2.7. Minería de Datos . . . . .	18
2.8. Enfoque propuesto . . . . .	18

<b>3. Interfaz Cerebro Computadora</b>	<b>20</b>
3.1. Plataformas Interfaz Cerebro Computadora . . . . .	20
3.2. Placa “Heart and Brain SpikerShield” . . . . .	21
3.2.1. Modo de uso . . . . .	21
3.3. Experimentos . . . . .	21
<b>4. Metodología</b>	<b>25</b>
4.1. Sistema de adquisición de datos . . . . .	26
4.1.1. Ventana Inicio . . . . .	26
4.1.2. Ventana de Captura . . . . .	27
4.1.3. Ventana de Visualizado . . . . .	27
4.2. Procesamiento de los datos . . . . .	28
4.3. Almacenamiento . . . . .	29
<b>5. Clasificación de los datos</b>	<b>30</b>
5.1. Obtención de los datos . . . . .	30
5.2. Procesamiento de los datos . . . . .	31
5.3. Creación del modelo . . . . .	31
5.4. Entrenamiento del modelo . . . . .	32
5.5. Resultados . . . . .	33
<b>6. Conclusiones</b>	<b>36</b>
6.1. Aportaciones de la investigación . . . . .	37
6.2. Trabajo a futuro . . . . .	37
<b>Bibliografía</b>	<b>39</b>

---

---

# Índice de figuras

---

2.1. Zonas de posicionamiento de electrodos “Diez-Veinte”. Recuperado de: <a href="http://bit.ly/2j9iDzb">http://bit.ly/2j9iDzb</a> . . . . .	11
3.1. Colocación de electrodos. . . . .	22
3.2. Conexión a computadora. . . . .	22
3.3. Interfaz Spiker Recorder Software. . . . .	23
3.4. Prueba de EEG Fallida . . . . .	23
3.5. Prueba de EEG Satisfactoria . . . . .	24
4.1. Proceso general del sistema . . . . .	26
4.2. Ventana de Inicio . . . . .	26
4.3. Ventana de Captura . . . . .	27
4.4. Ventana de Visualizado . . . . .	28
4.5. Ejemplo del buffer adquirido . . . . .	28
4.6. Ejemplo de un archivo EDF. . . . .	29
5.1. Total de instancias EEG . . . . .	32

---

---

# Índice de tablas

---

2.1. Amplitud en micro Volts en ondas EEG . . . . .	6
2.2. Tipos de señales del cerebro . . . . .	6
5.1. Información de las muestras adquiridas . . . . .	30
5.2. Resultados WEKA con datos sin procesar . . . . .	33
5.3. Resultados WEKA con datos normalizados . . . . .	34
5.4. Resultados con datos del Corpus CHBMIT a los modelos ob- tenidos . . . . .	35

# INTRODUCCIÓN

---

El propósito de la computación  
es la comprensión, no los  
números.

---

Richard Hamming

## 1.1. Motivación

En los años recientes, el área de la salud se ha visto inmersa dentro del área de la computación. Los diferentes dispositivos diseñados para obtener diferentes tipos de señales y/o síntomas de pacientes, requiere un análisis minucioso para la obtención de un diagnóstico confiable[7].

Diferentes laboratorios han comenzado a desarrollar sistemas de interfaz Cerebro-Computadora, los cuales proporcionan capacidades de comunicación y control a personas con discapacidades motoras severas. Su progreso y la realización de las aplicaciones depende de evaluaciones sistemáticas y comparaciones de diferentes señales cerebrales, métodos de grabación, algoritmos de procesamiento, formatos de salida y protocolos operativos [34].

Las múltiples Interfaces Cerebro-Computadora(BCI) tienen una gran campo de estudio, en el cual poder determinar si son aptos o no para ciertas tareas médicas, y por ende, la confiabilidad que pueden brindar de las capturas que realizan. Es por ello, que el presente trabajo toma como referencia un BCI basado en Arduino, el cuál, al ser una plataforma Open Source, nos brinda la libertad de poder manipular los elementos de manera menos restrictiva.

Por otro lado, una de las principales actividades de los electroencefalógrafos ha sido el determinar la incidencia de una anomalía cerebral asociada con enfermedades nerviosas y mentales, la relación entre patrones electroencefalográficos particulares y entidades de la enfermedad o elementos de la misma; aunque, al revisar la literatura sorprende el hecho que muchos estudios publicados dejan mucho que desear en el diseño experimental[11].

El presente trabajo se orienta en proporcionar una herramienta que pueda ser utilizada por médicos dedicados a tratar con este tipo de señales.

En la sección 1.2 se describe y acota el problema para esta tesis; en la sección 1.3 se presentan los objetivos de la tesis; por último, en la sección 1.4, se expondrá brevemente la organización de la tesis.

## 1.2. Descripción del problema

La diversidad de dispositivos que permiten captar los diferentes tipos de señales que el ser humano puede generar, hace de este trabajo viable de realizar, para ello se recurre a uno de tantos dispositivos existentes en el mercado, la placa seleccionada es diseñada por la empresa "Backyard Brains", la plataforma nos permite captar las señales musculares, cerebrales y cardiovasculares del cuerpo humano.

El trabajo no abarca todas las señales existentes [9, 27, 30, 21, 17, 2], se limita a estudiar tan solo las señales electroencefalográficas; así también, debido a que las técnicas para el procesamiento de las señales son diversos [23, 28, 29, 4, 36, 24, 8, 19, 25] y dado que la aplicación que ofrece el fabricante para la plataforma esta limitada en cuanto a funcionamiento, se apuesta por diseñar una aplicación propia; la finalidad, poder generar un formato adecuado para un posterior tratamiento de las señales.

Posterior a la obtención de las señales y su almacenamiento, se pretende crear un modelo aplicando técnicas de aprendizaje automático, para el presente trabajo, se decidió trabajar con máquinas de soporte vectorial, esto debido, en gran medida, a la naturaleza de los datos.

La finalidad de lo anterior, es obtener un modelo que permita la clasificación de las señales adquiridas por la plataforma para un posible diagnóstico de ciertas enfermedades cerebrales.

### 1.3. Objetivos de la Tesis

#### ■ Objetivo general

- Desarrollar un modelo que permita la clasificación de señales cerebrales.

#### ■ Objetivos específicos

- Estudiar el funcionamiento del shield "Heart and Brain SpikerShield.<sup>en</sup> conjunto con Arduino para la adquisición de señales cerebrales.
- Estudiar la estructura del Formato de Datos Europeo(EDF).
- Diseñar un programa que permita la captura, guardado y visualización de las señales cerebrales adquiridas.
- Estudiar la técnica Máquina de Soporte Vectorial.

### 1.4. Estructura de la Tesis

En el capítulo 2 se presentan conceptos básicos relacionados al contenido de la tesis, los cuales incluyen términos sobre electroencefalografía, los tipos de señales cerebrales, así como una breve discusión sobre el formato a utilizar. Por último, se presenta una revisión de los trabajos relacionados en el ámbito de EEG.

En el capítulo 3 se detallan los experimentos realizados con la plataforma para observar su funcionamiento básico.

En el capítulo 4 se presenta la aplicación desarrollada, se describen los elementos que la conforman, la forma de procesar la información y su almacenamiento.

En el capítulo 5 se presenta el método propuesto, se presentan y discuten los resultados experimentales al aplicar aprendizaje automático.

Finalmente, en el capítulo 6 se ofrecen las conclusiones y trabajo a futuro que se desprende de este trabajo.

# ESTADO DEL ARTE

---

El cerebro no piensa ni en  
palabras ni en números; piensa  
en metáforas.

---

Jürgen Klaric

## Antecedentes

En este capítulo se introducen conceptos básicos los cuales resultan imprescindibles al abordar los capítulos siguientes. En la sección 2.1 se describen los aspectos básicos de la electroencefalografía. En la sección 2.2 se describe los tipos de señales, centrándose en las EEG. En la sección 2.3 se describen las características del formato EDF. Finalmente en la sección 2.4 se presentan un estudio del trabajo relacionado más relevante.

### 2.1. Electroencefalografía

La electroencefalografía es el registro de los potenciales eléctricos generados por el cerebro y obtenidos por medio de electrodos situados sobre la superficie del cuero cabelludo. Dicho registro posee formas muy complejas que varían respecto a la localización de los electrodos y entre individuos. Esto es debido al gran número de interconexiones que representan las neuronas y por la estructura no uniforme del cerebro.

Además, se usa para diagnosticar ciertos trastornos convulsivos, tumores cerebrales, daño cerebral de lesiones craneanas, inflamación cerebral o de la médula espinal, alcoholismo, ciertos trastornos psiquiátricos, y trastornos

metabólicos y degenerativos que afectan el cerebro [14]. También se usan para evaluar los trastornos del sueño.

## 2.2. Tipos de onda en señales

Las ondas que maneja el EEG poseen amplitudes que van desde los 10 mV en registros sobre el córtex, a 100  $\mu\text{V}$  en la superficie del cuero cabelludo (Tabla 2.1). Las frecuencias de estas ondas se mueven entre 0,5 y 100 Hz y dependen mucho del grado de actividad del córtex cerebral. La mayoría de las veces estas ondas no poseen ninguna forma determinada, en algunas son ritmos normales que suelen clasificarse en ritmos  $\alpha, \beta, \theta$  y  $\delta$  (Tabla 2.2).

Tipo de onda	Amplitud [ $\mu\text{V}$ ]
$\alpha$	20-60
$\beta$	10-15
$\theta$	50-100
$\delta$	70-100

Tabla 2.1: Amplitud en micro Volts en ondas EEG

Tipo de onda	Frecuencia[Hz]	Características
$\alpha$	8 y 13	Se registran en sujetos despiertos sin ninguna actividad y con los ojos cerrados. Se registran en las zonas parietal y frontal.
$\beta$	14 y 30 (50)	Se dividen en $\beta_1$ y $\beta_2$ . Las $\beta_2$ aparecen cuando se activa intensamente el SNC o cuando es sujeto está bajo tensión.
$\theta$	4 y 7	Se presentan en la infancia, aunque también en adultos en periodos de estrés emocional y frustración.
$\delta$	Menos de 3.5	Se presentan durante el sueño profundo, en la infancia y enfermedades orgánicas cerebrales graves.

Tabla 2.2: Tipos de señales del cerebro

## 2.3. Enfermedades cerebrales

El cerebro es un órgano muy delicado. Ciertos accidentes pueden producir lesiones cerebrales y el cerebro puede enfermar y dejar de funcionar de manera normal. Dichas enfermedades pueden producir diversos síntomas y el comprenderlos puede resultar difícil, requiere de un neurólogo o un psiquiatra, así como sofisticadas pruebas biomédicas.

La investigación sobre las alteraciones cerebrales requiere incluso de una mayor variedad de especializaciones. Algunas alteraciones como la epilepsia y la depresión son bastante comunes, incluso en niños y adolescentes. Otras menos habituales, como la esquizofrenia, otras habituales con la edad, como el Alzheimer, pero no menos importantes y/o dañinas.

### 2.3.1. Epilepsia

Durante una convulsión (ajuste epiléptico), la persona pierde la conciencia y puede incluso caer al suelo, ponerse rígido y temblar. Cuando vuelve en sí, se puede dar cuenta de que se ha mordido o incluso mojado. Después de estos episodios pueden estar confusos o somnolientos. Desgraciadamente, para algunos, estos episodios pueden aparecer con cierta frecuencia durante la semana o en el día.

¿Qué es lo que va mal? Durante las convulsiones hay un aumento en la descarga de potenciales de acción seguidos de un periodo de excitabilidad reducida. Cuando la reducción de la excitación es incompleta, las convulsiones pueden ser desencadenadas por la activación incontrolada de las neuronas vecinas. Esta activación incontrolada de las neuronas vecinas. Esta activación puede ser localizada (causando una convulsión parcial) o puede extenderse a lo largo de la corteza (convulsión generalizada)[7, 9].

Durante una convulsión generalizada, el ritmo alfa normal del electroencefalograma (EEG) es sustituido por ondas largas, lentas y sincronizadas de la actividad eléctrica en ambos hemisferios cerebrales.

### **Característica de las señales**

Un complemento para el estudio visual de las señales EEG, son los análisis matemático, estadístico y físico. Desde la década de los años 70, se han creado algoritmos que detectan automáticamente algunas características de interés en las señales EEG, especialmente las puntas, las cuales son un indicador fuerte de epilepsia. Sin embargo, la dificultad de distinguir entre puntas anormales y normales (como el ruido y artificios), no han permitido establecer métodos eficientes de clasificación [28].

De acuerdo a algunas investigaciones, la espiga puntiforme es la forma de onda más significativa en los registros de actividad cerebral de aquellos pacientes que padecen de epilepsia, y está definida como un transitorio que sobresale claramente de la actividad de fondo con picos muy puntiagudos cuya duración va de 70 a 120ms [15].

## **2.4. Captar señal EEG**

La actividad bioeléctrica cerebral puede captarse por diversos procedimientos:

- Sobre el cuero cabelludo.
- En la base del cráneo.
- En cerebro expuesto.
- En localizaciones cerebrales profundas.

### **2.4.1. Tipos de electrodos**

Los electrodos son placas metálicas utilizadas como un conductor encargado de realizar contacto con algún sector del circuito que no sea de tipo metálico. Tiene como finalidad el transporte de la corriente eléctrica. Es un término que deriva del griego, “elektron” es la palabra de donde proviene electricidad y “hodos” cuyo significado es camino [6]. Para la captación de señales se utilizan diferentes tipos de electrodos:

### Superficiales

- **Adheridos:** Son pequeños discos metálicos de 5mm de diámetro. Se adhieren con pasta conductora y se fijan con colodión que es aislante. Aplicados correctamente, dan resistencias de contacto muy bajas (1-2 kilo ohmios).
- **De contacto:** Consisten en pequeños tubos de plata clorurada rosca-dos a soportes de plástico. En su extremo de contacto se colocan una almohadilla que se humedece con solución conductora. Se sujetan al cráneo con bandas elásticas y se conectan con pinzas de “cocodrilo”. De colocación fácil, pero incómodos para el paciente.
- **En casco de malla:** De reciente introducción. Los electrodos están incluidos en una especie de casco elástico. Como características importantes, presentan la comodidad de colocación, óptimos para registros de larga duración, inmunidad a los artefactos y la precisión de su colocación.
- **De aguja:** De uso limitado; solo se emplean en recién nacidos y en UCI. Pueden ser desechables o de uso múltiple.

### Basales

- **Faríngeo:** Tubo de plata de 12.5 cms de largo y 2.5mm de grosor. Su utilidad puede ser nula por los artificios que simulan ondas agudas o en punta originadas por la contracción de músculos nasofaríngeos.
- **Timpánico:** Tubo de plata de 6cm de largo y 2.5mm de espesor, en forma de S para adaptarlo a la curvatura del conducto auditivo externo. Se pone en contacto con el tímpano y registra la actividad eléctrica de la base del lóbulo temporal.
- **Esfenoidal:** Aguja hipodérmica de acero de 5cm de largo y 0.6mm de diámetro, aislada, excepto en su punta. Construido para explorar a cara basal de la parte anterior del lóbulo temporal y es posiblemente el electrodo de elección entre los basales

### Quirúrgicos

- **Corticales:** Registran la actividad eléctrica del cerebro al ponerse en contacto directo con éste, en la craneotomía.
- **Intracerebrales:** Han modificado las nociones sobre epilepsia. Unos se implantan y se retiran en el mismo acto quirúrgico y otros son de implementación crónica hasta de dos meses de duración.

### 2.4.2. Sistema de posicionamiento de los electrodos

Para los equipos de lectura de actividad eléctrica, existen distintos criterios para la distribución de los electrodos en la corteza, el más utilizado actualmente es el “Diez-Veinte” (Fig. 2.1), su distribución se realiza de la siguiente manera [29].

- **Puntos Fp y O:** Se toma la distancia entre el nasión (área entre los ojos y el puente de la nariz) y el inión (la parte más sobresaliente del hueso occipital), pasando por el vertex (parte superior de la cabeza). 10 % por encima del nasión se coloca el punto Fp (Frontal polar) y 10 % sobre el inión el O (Occipital).
- **Puntos Fz,Cz,Pz:** A distancias equidistantes equivalentes al 20 % de la medida entre el nasión y el inión se colocan 3 puntos más el Fz(Frontal), el Cz(Central) y el Pz(Parietal).
- **Puntos T3 y T4:** Tomando como referencia la distancia entre los puntos pre-auriculares, al 10 % por encima de cada uno se colocan los puntos T3 y T4, llamados temporales mediales.
- **Puntos C3 y C4:** Se colocan a un 20 % por encima de los puntos T3 y T4.
- **Puntos F3 y F4:** Se colocan a una distancia equidistante entre el punto Fz y la línea de electrodos temporales (T3,T4,C3,C4 Y Cz).
- **Puntos P3 y P4:** Se colocan a una distancia equidistante entre el punto Pz y la línea de electrodos temporales.

- **Puntos Fp1, Fp2, O1 y O2:** Se toma la distancia entre el punto medio de Fp y O a través de T3 y al 10 % de esa distancia, a través de Fp, se colocan los puntos Fp1 y Fp2 al igual para el punto O, se colocan los puntos O1 y O2.
- **Puntos F7 y F8.** Se colocan a una distancia equidistante entre Fp1 y T3, así como Fp2 y T4 respectivamente.
- **T5 y T6:** Se colocan a una distancia equidistante entre O1 y T3, así como O2 y T4 respectivamente.
- **Puntos A1 y A2:** Se colocan debajo de los puntos T3 y T4.

Los electrodos del lado izquierdo siempre llevarán los números impares y los del lado derecho los pares.

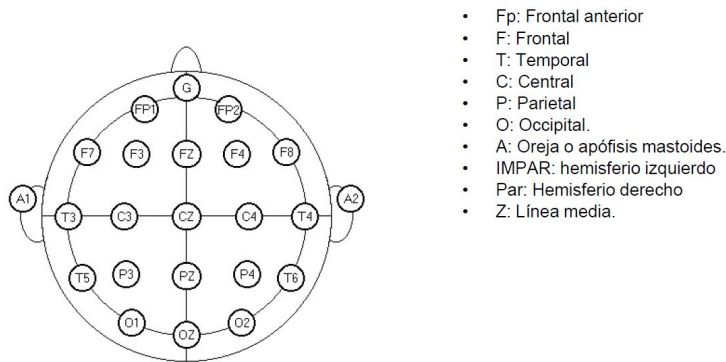


Figura 2.1: Zonas de posicionamiento de electrodos “Diez-Veinte”. Recuperado de: <http://bit.ly/2j9iDzb>

## 2.5. Formato de Datos Europeo (EDF)

Desarrollado en 1987 por un par de ingenieros europeos “médicos” para el “International Sleep Congress”, es un formato simple y flexible para el intercambio y almacenamiento de señales biológicas y físicas de varios canales [20].

Luego de su introducción en 1992, EDF se convirtió en el estándar para grabar las capturas de EEG y PSG, aunque con ciertas restricciones. Con EDF+, una variante de EDF, todas las señales, anotaciones y eventos son grabados en una sola sesión usando un sistema de grabación que puede guardarse de forma segura en un solo archivo.

### Especificaciones adicionales de EDF+

1. En la cabecera, usar solo caracteres US-ASCII con valor de byte 32...126.
2. Los campos “startdate” y “starttime” de la cabecera deberán contener solo caracteres 0-9, y el punto(.) como un separador.
3. El campo “local patient identification” debe empezar con los subcampos, separados por espacio:
  - El código con el cual es conocido el paciente en la administración del hospital.
  - Sexo(F o M).
  - Fecha de nacimiento. Con formato dd-MMM-yyyy.
  - Nombre del paciente.

Cualquier espacio dentro del código del hospital o el nombre del paciente debe ser reemplazado por un carácter diferente, por ejemplo ‘\_’. Los subcampos cuyo contenido es desconocido, no aplica o es anónimo será reemplazado por un carácter simple ‘X’.

4. El campo “local recording identification” debe empezar con los subcampos, separados por espacio:
  - El texto ‘Startdate’.
  - El campo “startdate” en formato dd-MMM-yyyy.

- El código de administración del hospital de la investigación.
- Un código especificando al responsable de la investigación o técnico.
- Un código especificando el equipo usado.

Cualquier espacio dentro de los códigos anteriores debe ser reemplazado por un carácter diferente, por ejemplo '\_'. Los subcampos cuyo contenido es desconocido, no aplica o es anónimo será reemplazado por un carácter simple 'X'.

5. “Digital maximum” debe ser más grande que “Digital minimum”. En caso de un amplificador de ganancia negativa correspondiente a “Physical maximum” sea más pequeño que “Physical minimum”, revisar como aplicar “negatividad hacia arriba” aplicada en Neurofisiología Clínica, a la señal ordinaria física. En caso de señales no calibradas, el campo “Physical dimension” se deja vacío, mientras “Physical maximum” y “Physical minimum” aún tienen valores diferentes.
6. No utilizar cualquier símbolo de agrupación de dígitos en los números. No usar coma ',' para separar decimales, en su lugar, usar el punto '.'.
7. Las muestras de señales ordinarias (2 bytes de enteros) deben ser almacenados en formato 'little endian, esto es, el bit menos significativo primero.
8. El campo “starttime” debe ser de acuerdo al tiempo local donde se encuentra el paciente cuando la captura se realiza.
9. Usar textos estandar y reglas de polaridad.
10. El campo 'number of data records' puede ser -1 durante el muestreo. Tan pronto como el archivo se cierre, deberá ser actualizado con el número correcto.
11. Si han sido aplicados filtros (HighPass, LowPass o Notch), especificarlo en el campo “prefiltering” de la cabecera.
12. El campo “transducertype” debe especificar el sensor utilizado.

### 2.5.1. Fórmulas utilizadas en EDF

Para el correcto funcionamiento, se debe considerar el factor de escala aplicado considerando la mínima y máxima amplificación física o digital, para realizar un correcto escalado se debe recurrir a la información del encabezado como las medidas máxima y mínima, además de la amplificación digital. También se considera el Offset, siguiendo para estos puntos las siguientes formulas:

$$FactorDeEscala = \frac{MaximaMedicion - MinimaMedicion}{EscaladoMaximo - EscaladoMinimo}$$

$$Offset = MaximaMedicion - FactorDeEscala * EscaladoMaximo$$

Considerando el factor de escala y el nivel DC añadido a cada medición, los datos resultantes serán adaptados siguiendo la fórmula siguiente:

$$MuestraReal = MuestraAlmacenada * FactorDeEscala + Offset$$

### 2.5.2. Uso de formato EDF

La razón de utilizar el formato EDF, de acuerdo a lo explicado anteriormente, es el estándar que plantea para el intercambio de información en señales de electroencefalograma y polisomnografía.

#### Ventajas

- Cualquier equipo electrónico que capte señales puede ser utilizado.
- Trata con las señales en crudo. Esto permite que los resultados puedan ser ajustados de una forma sencilla mediante las fórmulas que se tienen establecidas.
- Contiene información específica de los elementos que se utilizaron para cada señal, por ejemplo, los electrodos utilizados, el tipo de medición en cada electrodo (temperatura, voltaje, etc).
- El tratamiento a futuro que pudiera darse a la información, utilizando aplicaciones que permitan el manejo de este tipo de formato.

### Desventajas

- Puede resultar difícil adaptarse a otros problemas distintos a EEG y PSG.
- Se deben conocer detalles técnicos del equipo utilizado.

## 2.6. Trabajo relacionado

A continuación se presentan los trabajos centrales que se han realizado con base a la clasificación de señales EEG. Para comenzar, se hace referencia al estudio que motiva la presente tesis. Posteriormente, se detallan los trabajos de las diferentes técnicas empleadas para clasificación de señales EEG; por último, se menciona en el ámbito donde se encuentra el presente trabajo.

### 2.6.1. Ritmo de Berger

La existencia de la actividad eléctrica del cerebro fue descubierta hace más de un siglo por Caton. Después de la demostración de que el EEG podría ser grabado en el cuero cabelludo realizada por Hans Berger en la década de 1920, fue lentamente aceptado como un método de análisis de las funciones cerebrales en la salud y la enfermedad. Es interesante notar que la aceptación se produjo sólo después de la demostración de Adrián y Mathews en la década de 1930 de que el EEG, es decir, el ritmo Alfa, probablemente se generó en los lóbulos occipitales del hombre.

El EEG consiste esencialmente en la suma de actividad eléctrica de las poblaciones de neuronas, con una modesta contribución de las células gliales. Teniendo en cuenta que las neuronas son células excitables con propiedades eléctricas intrínsecas características y que la comunicación interneuronal está esencialmente mediada por procesos electroquímicos en las sinapsis, se sigue que estas células pueden producir campos eléctricos y magnéticos que pueden ser registrados a una distancia de las fuentes, es decir, cerca de la superficie cortical, o incluso del cuero cabelludo [31].

Berger sugirió que un EEG complejo se compone de dos formas de ondas fundamentales: lo más grandes de 100  $\mu s$ , ondas alfa que se correlacionan

con la actividad mental de los "concomitantes físicos de los fenómenos conscientes", y los  $35 \mu s$  de ondas más pequeñas beta que se asociaron con las actividades metabólicas de tejido cortical. Este análisis del EEG humano en términos de ondas alfa y beta podrían utilizarse para explicar resultados de algunos experimentos, así como los patrones de EEG característicos de las convulsiones de grandes males.

Aunque la correlación entre estos dos tipos de ondas eléctricas y diferentes tipos de actividad cortical ha sido abandonada, la caracterización de Berger del EEG en componentes alfa y beta sigue siendo fundamental para las aplicaciones clínicas y de investigación de EEG [26].

El presente trabajo se centra, como base teórica, en el conocido "Ritmo de Berger" [10], donde la idea fundamental es tomar los registros de las señales obtenidas de los electrodos colocados en la región occipital de la cabeza. Lo que obtenemos son las ondas alfa, que se producen cuando el sujeto cierra los ojos; y las beta, cuando los abre. Hay variaciones en el tamaño de las ondas y a veces del ritmo en la forma intermitente en la que aparecen, pero su frecuencia es tan característica y tan constante que nunca hay duda en cuanto su presencia.

De lo anterior desprende otro tipo de señales mucha más pequeñas, las cuales son conocidas como Potencial Evocado(PE), el cual es producido mediante estímulos visuales, auditivos ó somatosensoriales, generalmente son de voltaje mucho más bajo que la actividad cerebral cortical espontánea en curso. Por lo general no son evidentes en las grabaciones EEG ordinarias y se detectan con el uso de técnicas de promedio. Clínicamente, las pruebas EP se consideran mejor como una extensión del examen neurológico. Las anomalías identifican y sugieren la localización de una lesión responsable.

### **2.6.2. Detección y clasificación de enfermedades cerebrales**

Se puede encontrar trabajos de investigación donde se implementan diferentes técnicas de aprendizaje automático (ML por sus siglas en inglés), entre las que se identificaron: Máquina de soporte vectorial(SVM por sus siglas en inglés)[35, 5], Boosting, Naive Bayes, Análisis del Discriminante Li-

neal, Clasificación y árbol de regresión y Mapa de auto organización [33], por mencionar algunas. Por otro lado, el electroencefalograma (EEG) ha sido utilizado como herramienta para la detección de enfermedades cerebrales durante décadas[18], ya que contiene información fisiológica valiosa del cerebro.

La epilepsia es una enfermedad crónica con disfunción cerebral transitoria que resulta de la descarga anormal repentina de neuronas en el cerebro. El EEG es un método de detección inocuo y no invasivo, que desempeña un papel importante en la detección de enfermedades neurológicas[37].

Un método para la detección de convulsiones epilépticas consiste en utilizar ML para construir clasificadores para pacientes específicos que detectaran cuadros de un ataque epiléptico a través de un análisis EEG que permite obtener medidas de forma no invasiva de la actividad eléctrica del cerebro. El objetivo es construir una función que contruya un vector característico derivado de un EEG, donde se extraen estructuras espectrales con una ventana de 2 segundos por intervalos largos, se descartan las actividades que no son indicadores fiables [24, 36].

En este enfoque, se extraen características de EEG por fractales múltiples de fluctuaciones sin tendencia (MF-DFA) durante una primera etapa. En seguida, utiliza un algoritmo genético (GA) para calcular los parámetros utilizados en la SVM y clasificar los datos de entrenamiento de acuerdo a las características seleccionadas mediante el uso de SVM. Por último, el clasificador SVM se explota para detectar enfermedades neurológicas. Los resultados muestran un 99 % de efectividad para la detección de enfermedades reales[37].

Otro trabajo propone un nuevo método nuevo para la detección de señales epilépticas utilizando un análisis basado en wavelets envolventes(EA) del conjunto de la red neuronal normal(NNE), e interictal. La transformada wavelet discreta (DWT) en combinación con EA permite desarrollar un método para extraer características significativas de las señales EEG. Se obtiene una precisión del 98.78 % [22].

La clasificación en tiempo real de las señales EEG, es el objetivo fundamental del trabajo detallado a continuación, como características particulares se consideran las señales de baja amplitud, requiere de la adaptación de las estrategias como la transformada wavelet, el análisis de componentes princi-

pales y las maquinas de soporte para el procesamiento de señales, análisis y clasificación de las mismas. Se obtiene un resultado por encima del 90 % [16].

## 2.7. Minería de Datos

La minería de datos es el estudio de la recolección, limpieza, procesamiento, análisis y obtención de información útil a partir de datos. En la era moderna, virtualmente todos los sistemas automatizados generan alguna forma de datos, ya sea para fines de diagnostico o análisis. Esto ha resultado en un diluvio de datos, que ha estado alcanzando el orden de petabytes o exabytes[1].

Se basa fundamentalmente en el diseño de métodos y algoritmos capaces de aprender a partir de datos empíricos, entre los que se encuentran:

- Aprendizaje supervisado
- Aprendizaje no supervisado
- Aprendizaje por refuerzo
- Aprendizaje semi-supervisado.

El proceso de minería de datos es un proceso que contiene fases tales como:

- Recolección de datos
- Extracción de características y limpieza de datos
- Proceso analítico y algoritmos

## 2.8. Enfoque propuesto

En el presente trabajo, el objetivo es desarrollar una interfaz cerebro computadora(BCI), la cuál consiste en múltiples fases incluidas: el pre-procesamiento, extracción de características, clasificación de señal y por ultimo el control de las mismas. Debido a la diversidad de dispositivos BCI en el mercado, el primer paso es determinar el tipo de plataforma Arduino a utilizar, en este caso,

se decidió por un entorno desarrollado por "BackYard Brains", se detallará más a fondo en el siguiente capítulo.

Otro aspecto importante, son las señales con las cuales se debe trabajar, de acuerdo a la literatura, las señales más factibles de analizar son las Alfa y Beta, esto debido a que se presentan con mayor frecuencia en la actividad cerebral, por ejemplo, en la relajación o estado de somnolencia la actividad alfa aumenta y en estado de vigilia con los ojos abiertos la actividad beta es dominante.

Por otro lado, para el almacenamiento de las señales se opta por el formato EDF, ya que posee ventajas para trabajar con las señales en crudo, solo basta con tener la configuración óptima la cual depende de las características de la plataforma a trabajar.

Cabe mencionar que la base de corpus a utilizar fue extraída de PhysioNet [13], la cuál ofrece acceso libre a una colección de grabación de señales fisiológicas. Provee además una herramienta open source para el análisis de las mismas.

Por último, para el presente trabajo se optó por las Máquinas de Vectores de Soporte para clasificación de las señales, el objetivo de esto es dado un conjunto de entrenamiento con sus etiquetas de clase (se obtiene de la base de datos de PhysioNet), se entrena la máquina de soporte vectorial para construir un modelo que prediga la clase de una nueva muestra o conjunto de test (las muestras que se generaran con la aplicación del presente trabajo).

# INTERFAZ CEREBRO COMPUTADORA

---

Never promise more than you  
can perform

---

Publilius Syrus

## 3.1. Plataformas Interfaz Cerebro Computadora

Las plataformas BCI, por sus siglas en ingles Brain Computer Interface, son definidas como una combinación de hardware y software que permiten controlar dispositivos externos o incluso computadoras mediante señales cerebrales. La investigación en este campo ha atraído el mundo académico y la industria por igual. El objetivo primordial es ayudar a las personas con discapacidad grave a vivir su vida como personas normales tanto como sea posible[32].

Algunas plataformas suelen ser de código cerrado, es decir, que no está disponible al público para su uso/modificación, que se utilizan principalmente para la creación de prototipos y pruebas internas. Por otra parte, estas herramientas necesitan de una amplia documentación que normalmente no es accesible para otros usuarios, sin previa adquisición y pago del producto.

No obstante, fuera de los laboratorios de empresas privadas, han surgido varias plataformas BCI a disposición de científicos o usuarios: enfocadas a su libre uso disponiendo del código abierto (Open Source) y licencias GNU pú-

blicas, facilitando la modificación y la inclusión de aportaciones de terceros[3].

De acuerdo a lo anterior, para el presente trabajo se ha utilizado la plataforma "Heart and Brain SpikerShield", se presentan sus características en la siguiente sección.

## 3.2. Placa “Heart and Brain SpikerShield”

Es desarrollada por “Backyard Brains” - una empresa dedicada a introducirnos a la rama de la neurociencia- con esta plataforma se puede observar y grabar los potenciales de acción del corazón y los ritmos lentos del cerebro utilizando su aplicación “Spike Recorder Software”. Al estar basado en la ideología de hardware libre, se pueden hacer diversos experimentos e interfaces, por ejemplo, utilizar los latidos del corazón para controlar un tambor de juguete o las luces.

La plataforma cuenta con una placa denominada “Shield”, su función principal es amplificar las señales captadas del cerebro, esto hace más fácil la lectura de las mismas; posteriormente es recibida por Arduino, desde la cuál se envía la información a una computadora y poder procesarla mas cómodamente, sin necesidad de saturar el procesador de Arduino.

### 3.2.1. Modo de uso

La ubicación de los electrodos es tomada del sistema 10-20, del cuál, solo colocaremos electrodos en las posiciones O1, O2 y , A1 o A2, tal como se muestra en Fig 3.1.

Una vez colocados los electrodos, conectar el Arduino a una computadora. Encenderá una luz la cuál significa que está lista para trabajar (Fig 3.2).

## 3.3. Experimentos

Se experimentó con el Shield y el Arduino para conocer el funcionamiento del mismo, para estas pruebas fue necesario modificar los parámetros por defecto, para la visualización de los resultados, se utilizó la interfaz que viene



Figura 3.1: Colocación de electrodos.




Figura 3.2: Conexión a computadora.

junto con la plataforma, aunque sencilla, resulta de gran ayuda a la hora de utilizarla.

Se utilizó la herramienta que incorpora el programa (Fig. 3.3), la cual tiene una función para aplicar la Transformada Rápida de Fourier (FFT) y poder ubicar el dominio de las distintas señales captadas por los sensores, en este trabajo solo se consideran las señales Alfa y Beta.

La realización de las pruebas se tuvieron en cuenta los siguientes puntos:

- Un lugar silencioso.
- Se realizaban pruebas de un minuto para verificar que hubiera una lectura adecuada de los sensores.
- Se sienta a la persona y se pide hacer el menor movimiento posible de su cuerpo, los ojos los podía abrir y cerrar en cualquier momento.

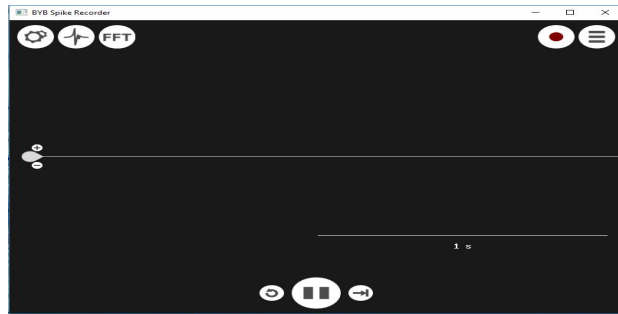


Figura 3.3: Interfaz Spiker Recorder Software.

- El proceso de adquisición de datos es de solo 5 minutos.

En los primeros experimentos se obtenían datos muy dudosos acerca de lo que se observaba en la aplicación, pues aunque en la herramienta FFT se mostraban dominios correctos, en su mayoría era una señal con ruido, poco o nada que ver con las señales a encontrar (Fig. 3.4).

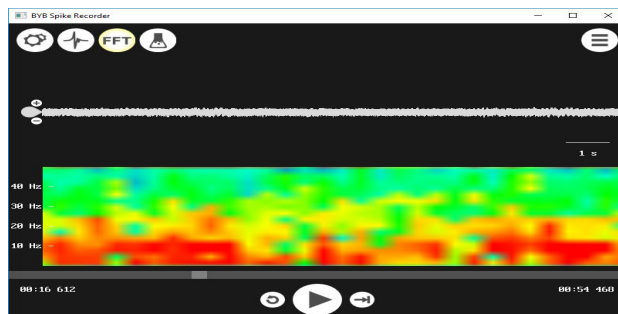


Figura 3.4: Prueba de EEG Fallida

El uso de la computadora conectada a la corriente es generador de ruido, basta con desconectarla y usarla con la batería, aunque varios experimentos se habían realizado con la batería puesta, se seguía obteniendo resultados erróneos; por ello, como segundo paso, se analizó la posición de los electrodos, se encontró que la distancia entre los electrodos de la cinta colocada en la cabeza no era la correcta, estaban demasiado cerca uno de otro, esto provocaba parte del ruido en la señal.

Tras varios experimentos ya con los electrodos colocados correctamente, se

pudo encontrar que ambas señales eran detectadas por la plataforma, como se puede observar en 3.5.

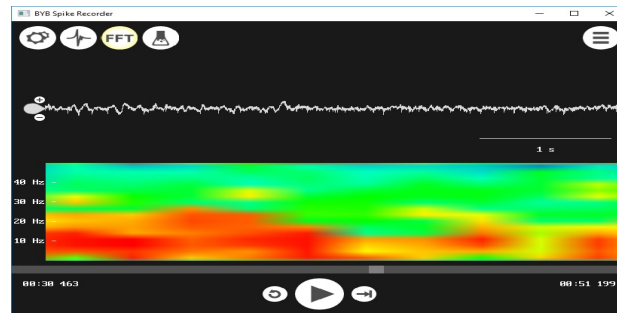


Figura 3.5: Prueba de EEG Satisfactoria

## METODOLOGÍA

---

Los hombres lo deberían saber  
todo del cerebro y sólo del  
cerebro, surgen nuestros  
placeres, alegrías, risas y  
bromas, así como nuestros  
dolores, penas y lágrimas. A  
través de él pensamos, vemos,  
oímos y distinguimos lo feo de lo  
bonito, lo malo de lo bueno, lo  
agradable de lo desagradable

---

Hipócrates

En el capítulo anterior, se describió la forma del funcionamiento de la plataforma Arduino y la interfaz que permite manipular la placa. Aunque para propósitos de esta tesis, es necesario realizar una nueva aplicación “ad hoc” a los requerimientos que pretendemos abordar.

Los datos empleados para la realización de este trabajo provienen de dos fuentes: de un lado, de los sensores de la plataforma Spiker Shield y el sistema propuesto, y por otro lado, de las fórmulas que se utilizan para elaborar el formato EDF. Este capítulo pretende ofrecer una descripción detallada del sistema desarrollado, los procedimientos y técnicas empleadas para alcanzar los resultados en este trabajo.

A continuación se muestra el proceso de forma simplificada, el proceso de captura y el almacenamiento en formato EDF (Fig. 4.1).

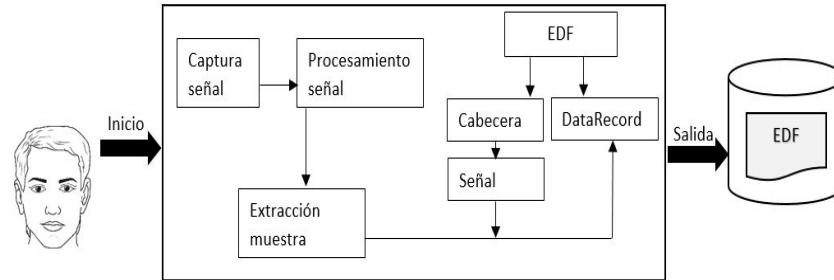


Figura 4.1: Proceso general del sistema

## 4.1. Sistema de adquisición de datos

Para la adquisición de datos, fue necesario diseñar un interfaz sencilla para captar las señales EEG enviadas desde la placa Arduino, permitiendo visualizar las señales capturadas y posteriormente almacenarlas en un archivo. La aplicación se divide en dos secciones, la primera permite la captura de las señales y la segunda visualizar la información de archivos EDF.

### 4.1.1. Ventana Inicio

Como primer elemento se visualiza una ventana donde seleccionar el modo en que se desee ejecutar (Fig. 4.2), ya sea la opción de Captura o la de Visualización.

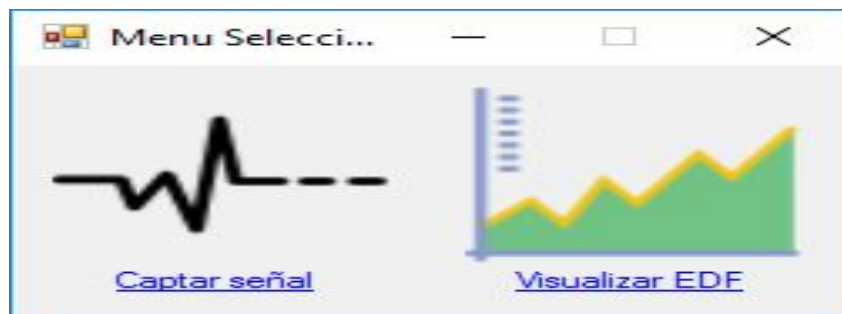


Figura 4.2: Ventana de Inicio

### 4.1.2. Ventana de Captura

En esta ventana, se puede iniciar la captura de las señales para posteriormente guardar en un archivo EDF. La interfaz (Fig. 4.3) resulta sencilla de utilizar.

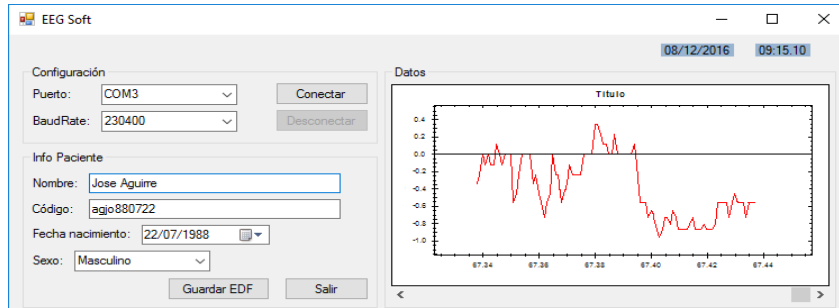


Figura 4.3: Ventana de Captura

Esta ventana cuenta con 3 secciones básicas a detallar:

- **Configuración:** Permite indicar el puerto y la velocidad de BaudRate con la que funciona la placa utilizada, en este trabajo, los valores por defecto son:
  - Puerto: COM3.
  - BaudRate: 230400.
- **Info. Paciente:** Permite ingresar información necesaria para la elaboración del archivo EDF, entre los que destaca el Nombre del paciente, código con el cual identificar al paciente, fecha de nacimiento y el sexo del paciente. En esta misma sección se tiene el botón de Guardar EDF.
- **Datos:** Muestra un pequeño gráfico de la señal captada al momento.

### 4.1.3. Ventana de Visualizado

Por último, se tiene la ventana donde se puede visualizar un archivo EDF y las señales que contiene.





---

# CLASIFICACIÓN DE LOS DATOS

---

Data is the new oil.

---

Clive Humby

## 5.1. Obtención de los datos

Los datos han sido recabados mediante la plataforma mencionada en el Capitulo 3. Las muestras se han tomado de acuerdo a las especificaciones en 3.3, la única variante ha sido el tiempo en el que se ha realizado el muestreo, este ha sido de 30 minutos aproximadamente para cada persona.

Por otro lado, se han tomado muestras a 10 personas(entre 20 y 30 años), la tabla (5.1)presenta información acerca de las mismas.

ID.Persona	Sexo	Edad	Epilepsia
Persona1	M	24	S
Persona2	F	21	S
Persona3	F	21	N
Persona4	M	22	N
Persona5	F	29	N
Persona6	M	25	N
Persona7	M	24	N
Persona8	F	30	N
Persona9	M	24	N
Persona10	F	25	N

Tabla 5.1: Información de las muestras adquiridas

## 5.2. Procesamiento de los datos

Se ha realizado un procesamiento sobre los archivos en formato EDF, el cual consiste en extraer el conjunto de DataRecords pertenecientes a cada paciente, cada uno contiene 256 muestras, como ya se ha mencionado, representan un segundo de muestreo. Se consideran éstas 256 muestras como características para la creación de un modelo, agregando a su vez, una característica de clase, la cual define si en ese periodo existe alguna señal con cierta anomalía (S o N).

De acuerdo al conjunto de datos, una señal se define en la clase “S” si tiene un valor mayor a 11, de lo contrario se coloca en la clase “N”. Una vez aplicado el proceso anterior en los archivos EDF generados, se obtiene aproximadamente un total de 140,000 muestras, de las cuales:

- 18,149 están catalogadas con epilepsia (Clase “S”).
- 121,851 están catalogadas con epilepsia (Clase “N”).

## 5.3. Creación del modelo

Para la creación del modelo se recurre al software “WEKA” [12], el cuál contiene una colección de algoritmos de aprendizaje automático. Como primer paso, se debe tomar en cuenta la cantidad de instancias en las clases, de acuerdo a la teoría, es importante que estén balanceadas, es decir, que contengan un número semejante de instancias. Para ello, se realiza una operación para remover un rango de valores (“RemoveRange”) y tener un balanceo en las muestras, el proceso se aplicó a un rango específico de la clase N.

Con lo anterior, se obtuvo un total de 37,084 muestras(Fig. 5.1):

- 18,149 están catalogadas con epilepsia (Clase “S”).
- 18,935 están catalogadas con epilepsia (Clase “N”).

Ya con un numero de instancias similares por cada clase, se puede proceder a entrenar un modelo.

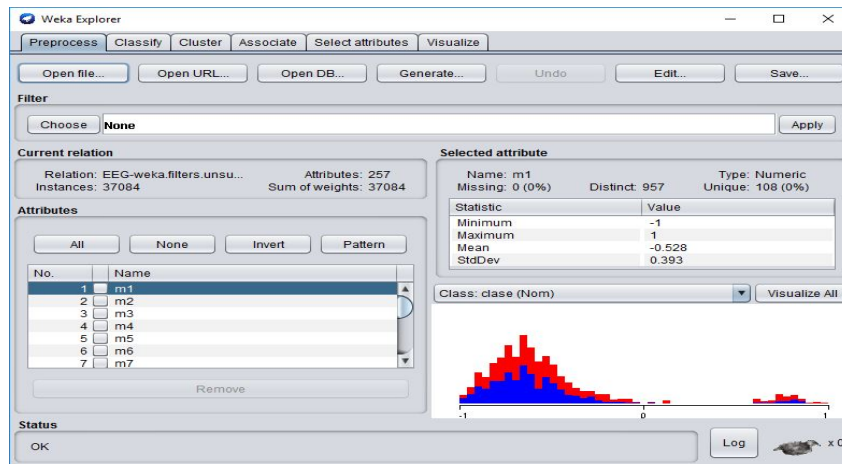


Figura 5.1: Total de instancias EEG

## 5.4. Entrenamiento del modelo

Para esta sección, es necesario elegir entre las diversas técnicas de aprendizaje automático, en el presente trabajo se optó por utilizar la técnicas de Máquinas de Soporte Vectorial(SVM), esto en gran medida a la forma de los datos a analizar.

Con el conjunto de datos adquirido previamente, se han realizado diversas pruebas para obtener un modelo con un resultado aceptable, y a su vez, analizar la forma en que pueden impactar en los resultados los mismos. A continuación se resumen las pruebas a realizar:

- Datos sin normalizar: Los datos tal cuál han sido adquiridos.
- Datos normalizados: Se aplica un proceso para ajustar los valores a un rango más pequeño a analizar. Se utilizó una escala de -1 a 1.
- Parámetros de SVM: Principalmente, hacer uso de los diversos Kernels de una SVM, se consideran los Kernels “Polinomial” y “Función de Base Radial(RBF)”.

Por otra parte, se utilizaron las opciones “División porcentual” a un 66 % y “Validación cruzada” a 10 pliegues para el entrenamiento del modelo.

## 5.5. Resultados

Las diferentes configuraciones del SVM, así como la representación de los datos fue un factor importante a la hora de obtener los resultados.

La tabla 5.2 presenta los resultados con los datos obtenidos directamente de los archivos EDF, es decir, sin normalizar.

Datos sin normalizar			
Clasificador	Configuración	Correctamente clasificados	Incorrectamente clasificados
SVM	División Porcentual K = RBF C = 1.0 G = 0.0	68.10 %	31.90 %
SVM	Division Porcentual K = Polinomial C = 1.0 G = 0.0	55.19 %	44.81 %
SVM	<b>Validación Cruzada</b> K = RBF C = 1.0 G = 0.0	<b>71.78 %</b>	<b>28.22 %</b>
SVM	Validación Cruzada K = Polinomial C = 1.0 G = 0.0	54.07 %	45.93 %

Tabla 5.2: Resultados WEKA con datos sin procesar

Podemos observar en la tabla 5.2 que el mejor resultado fue con las opciones “Validación cruzada”, kernel RBF, obteniendo un 71.78 % de instancias correctas.

En seguida, se normalizaron los datos en un rango -1,1, el cual mejoró un poco los resultados. La tabla 5.3 presenta los resultados correspondientes.

Podemos observar que en la tabla 5.3 se tiene una configuración adicional, la cuál presentó el mejor resultado de clasificación, que obtuvo un 73.17 %. Cabe aclarar que dicha configuración se aplicó a los datos sin normalizar, pero debido al rango que se maneja es un poco más alto, el proceso al crear el modelo tiende a durar muchos más tiempo, por lo que se decidió omitir este modelo.

Datos normalizados			
Clasificador	Configuración	Correctamente clasificados	Incorrectamente clasificados
SVM	División Porcentual K = RBF C = 1.0 G = 0.0	64.63 %	35.37 %
SVM	División Porcentual K = Polinomial C = 1.0 G = 0.0	61.17 %	38.83 %
SVM	Validación Cruzada K = RBF C = 1.0 G = 0.0	64.56 %	35.44 %
SVM	Validación Cruzada K = Polinomial C = 1.0 G = 0.0	62.08 %	37.92 %
<b>SVM</b>	<b>Validación Cruzada</b> <b>K = RBF</b> <b>C = 1000</b> <b>G = 10</b>	<b>73.17 %</b>	<b>26.83 %</b>

Tabla 5.3: Resultados WEKA con datos normalizados

Por último, se consideraron datos del corpus elaborado por el MIT (Physionet), dicha base de datos recolecta grabaciones EEG de sujetos pediátricos con crisis intratables. Se seleccionaron datos al azar para probar con el modelo resultante de la investigación. Los resultados pueden observarse en la tabla 5.4.

De todos los experimentos realizados, la configuración de SVM más aceptable fue con el Kernel “Radial Basis Function” y los parámetros “Gamma=10.0” y “Costo = 1000”. En el siguiente capítulo se detallan las conclusiones y el trabajo a futuro.

Base de Datos CHBMIT			
Clasificador	Configuración	Correctamente clasificados	Incorrectamente clasificados
SVM	División Porcentual K = RBF C = 1.0 G = 0.0	25.37 %	74.63 %
SVM	División Porcentual K = Polinomial C = 1.0 G = 0.0	25.37 %	74.63 %
SVM	Validación Cruzada K = RBF C = 1.0 G = 0.0	25.37 %	74.63 %
SVM	Validación Cruzada K = Polinomial C = 1.0 G = 0.0	25.37 %	74.63 %
<b>SVM</b>	<b>Validación Cruzada</b> <b>K = RBF</b> <b>C = 1000</b> <b>G = 10</b>	<b>74.63 %</b>	<b>25.37 %</b>

Tabla 5.4: Resultados con datos del Corpus CHBMIT a los modelos obtenidos

## CONCLUSIONES

---

Education is not the piling on of learning, information, data, facts, skills, or abilities -that's training or instruction- but is rather making visible what is hidden as a seed.

---

Thomas Moore

El estudio de las señales del cerebro es un tanto complicado, dado que se debe adentrar en un mundo desconocido, pero a la vez fascinante; desde aprender los principios básicos de su funcionamiento, la forma en que se comunica mediante impulsos y señales, hasta los múltiples dispositivos capaces de hacer lecturas EEG. En mi opinión, de este trabajo concluiría que:

El uso de dispositivos de bajo costo para el estudio de señales EEG es interesante, por una parte, por lo sencillo que pueden llegar a ser en cuanto a su uso e implementación, y por otro; la confiabilidad de los datos que adquieren, este mucho más importante que el primero, pues de ello depende los resultados que se esperan obtener.

La plataforma “Spiker Shield”, a pesar de que posee tan solo dos electrodos, esta cumple su función para lectura de señales EEG. La placa puede detectar señales Alfa y Beta, las cuáles pueden ser estudiadas para encontrar anomalías en la función cerebral. Los experimentos se realizaron sin modificar el funcionamiento de la misma

El uso de un formato para el almacenamiento de las señales es esencial, ya que permite mantener un registro ordenado de los EEG realizados, para este punto se utilizo el formato EDF. Una de las mayores ventajas del formato es

la forma de trabajar con señales en crudo, pudiendo adaptarse a cualquier dispositivo.

Se compararon los datos adquiridos por la “Spiker Shield” con datos obtenidos por el MIT mediante una plataforma diferente; la diferencia, más sensores, otra configuración, otros valores, etc. Lo que nos lleva a hacernos la pregunta, ¿pueden compararse los datos obtenidos con otros datos de diferentes placas?. En primera instancia pudiera decirse que sí, pero al analizar los datos, vemos pequeñas variaciones en los valores obtenidos en cada una de las plataformas.

Como observación final, una forma de emparejar los datos obtenidos con la base de datos del MIT, podría ser modificando el funcionamiento de la placa, quizá no dependa tanto del hardware.

## 6.1. Aportaciones de la investigación

Las aportaciones del presente trabajo están directamente relacionadas con las conclusiones anteriores, entre ellas:

- Un sistema de adquisición de datos basado en C#.
- Uso del formato EDF para el almacenamiento de los datos.
- Un modelo basado en los datos adquiridos por la plataforma “SpikerShield”.

A nivel personal fue poder experimentar por primera vez, de forma superficial, en el mundo de la electrónica, en especial, en los sistemas embebidos y sobretodo, trabajar con los datos adquiridos de un órgano tan difícil de entender como lo es el cerebro humano.

## 6.2. Trabajo a futuro

Se cumplió el objetivo principal aunque en el camino se encontraron diversas formas con el cual abordar el tema para mejora de la investigación. Como trabajo futuro se espera:

- Implementar otros métodos para procesar series de tiempo.
- Clasificar la información en tiempo real.
- Estudiar la posibilidad de agregar más enfermedades cerebrales para su análisis.

---

---

# Bibliografía

---

- [1] Charu C Aggarwal. *Data mining: the textbook*. Springer, 2015.
- [2] A Al Raouf Bsoul, Kevin Ward, Kayvan Najarian, and Soo-Yeon Ji. A unified signal processing and machine learning method for detection of abnormal heart beats using electrocardiogram. In *Bioinformatics and Biomedicine Workshops (BIBMW), 2010 IEEE International Conference on*, pages 453–460. IEEE, 2010.
- [3] Francisco José Martínez Albaladejo, Pedro José García Laencina, and Germán Rodríguez Bermúdez. Estado del arte en plataformas software para el desarrollo de sistemas brain computer interface. *Anuario de Jóvenes Investigadores*, (7):9–11, 2014.
- [4] Naive Angulo, Jose Sanz, Victor Malavé, Mireya Barrera, Heriberto Spineti, and Pablo Guillén. Máquinas de aprendizaje para clasificar señales electroencefalográficas. *Avances en Sistemas e Informática*, 6(1):213–218, 2010.
- [5] Nedjem-Eddine Ayat, Mohamed Cheriet, and Ching Y Suen. Automatic model selection for the optimization of svm kernels. *Pattern Recognition*, 38(10):1733–1745, 2005.
- [6] R Barea Navarro. Instrumentación biomédica. *Universidad de Alcalá, departamento de Electrónica*, 1998.
- [7] Ali Bashashati, Mehrdad Fatourechi, Rabab K Ward, and Gary E Birch. A survey of signal processing algorithms in brain–computer interfaces based on electrical brain signals. *Journal of Neural engineering*, 4(2):R32, 2007.
- [8] Russell La Fayette Cecil, Lee Goldman, and Andrew I Schafer. *Goldman’s Cecil Medicine, Expert Consult Premium Edition–Enhanced On-*

- line Features and Print, Single Volume, 24: Goldman's Cecil Medicine*, volume 2. Elsevier Health Sciences, 2012.
- [9] Justin Dauwels and Francois Vialatte. Topics in brain signal processing. *Nanyang Technological University, Singapore (IEEE J-STSP)*, ISSN1941-0484, 2010.
- [10] Adrián E.D. Paet 4, vol. 57. the bebgee ehythm: Potential changes feom the occipital lobes in man. 1934.
- [11] RJ Ellingson. The incidence of eeg abnormality among patients with mental disorders of apparently nonorganic origin: a critical review. *American Journal of Psychiatry*, 111(4):263–275, 1954.
- [12] Eibe Frank, Mark Hall, Geoffrey Holmes, Richard Kirkby, Bernhard Pfahringer, Ian H Witten, and Len Trigg. Weka-a machine learning workbench for data mining. In *Data mining and knowledge discovery handbook*, pages 1269–1277. Springer, 2009.
- [13] Ary L Goldberger, Luis AN Amaral, Leon Glass, Jeffrey M Hausdorff, Plamen Ch Ivanov, Roger G Mark, Joseph E Mietus, George B Moody, Chung-Kang Peng, and H Eugene Stanley. Physiobank, physiotookit, and physionet components of a new research resource for complex physiologic signals. *Circulation*, 101(23):e215–e220, 2000.
- [14] RC Griggs, RF Jozefowicz, and MJ Aminoff. Approach to the patient with neurologic disease. *Cecil Medicine. 24th ed. Philadelphia, Pa: Saunders Elsevier*, 2011.
- [15] J Gutiérrez. Detección del foco epiléptico y su ruta de propagación. In *Congreso Latinoamericano de Ingeniera Boimédica*, 2001.
- [16] Daniela Iacoviello, Andrea Petracca, Matteo Spezialetti, and Giuseppe Placidi. A real-time classification algorithm for eeg-based bci driven by self-induced emotions. *Computer Methods and Programs in Biomedicine*, 122(3):293–303, 2015.
- [17] Eun-Hye Jang, Byoung-Jun Park, Sang-Hyeob Kim, Youngji Eum, and Jin-Hun Sohn. A study on analysis of bio-signals for basic emotions classification: Recognition using machine learning algorithms. In *Information Science and Applications (ICISA), 2014 International Conference on*, pages 1–4. IEEE, 2014.

- 
- [18] Jaeseung Jeong. Eeg dynamics in patients with alzheimer's disease. *Clinical neurophysiology*, 115(7):1490–1505, 2004.
- [19] Bashar Katirji. Clinical neurophysiology: clinical electromyography. *Philadelphia: Saunders Elsevier*, 2012.
- [20] Bob Kemp. European data format, June 2006. Accedido 01-Apr-2016.
- [21] Kyong Ho Lee and Naveen Verma. A low-power processor with configurable embedded machine-learning accelerators for high-order and adaptive analysis of medical-sensor signals. *Solid-State Circuits, IEEE Journal of*, 48(7):1625–1637, 2013.
- [22] Mingyang Li, Wanzhong Chen, and Tao Zhang. Classification of epilepsy eeg signals using dwt-based envelope analysis and neural network ensemble. *Biomedical Signal Processing and Control*, 31:357–365, 2017.
- [23] Yi-Hung Liu, Han-Pang Huang, and Chang-Hsin Weng. Recognition of electromyographic signals using cascaded kernel learning machine. *Mechatronics, IEEE/ASME Transactions on*, 12(3):253–264, 2007.
- [24] Gerardo Luna-Guevara. Reducción de ruido en señales de electroencefalograma: una aplicación para mejorar las imágenes de mapeo cerebral.
- [25] Andrea Mannini and Angelo Maria Sabatini. Machine learning methods for classifying human physical activity from on-body accelerometers. *Sensors*, 10(2):1154–1175, 2010.
- [26] David Millett. Hans berger: From psychic energy to the eeg. *Perspectives in biology and medicine*, 44(4):522–542, 2001.
- [27] R Morris and M Fillenz. Neurociencias. la ciencia del cerebro. *Asociación Británica de Neurociencias, Alianza Europea Dana para el Cerebro*, 2014.
- [28] Nelson Casta no, José Zapata, and Jairo Villegas G. Detection of epileptic spikes in electroencephalographic signals for patients with temporal lobe epilepsy using wavelets. *Ingeniería y Ciencia | ing.cienc.*, 5(9):145–165, 2009.

- 
- [29] Leonardo David Ojeda Ruiz et al. Sistema de control interpretando la actividad bioeléctrica de las señales cerebrales usando una interfaz bci. 2012.
- [30] Álvaro A Orozco-Gutierrez and Cristian Guarnizo Lemus. Análisis de reducción de ruido en señales provenientes de microelectrodos de registro. *Scientia et Technica*, 3(32):55–59, 2006.
- [31] Vilayanur S Ramachandran. *Encyclopedia of the Human Brain, Four-Volume Set*. Academic Press, 2002.
- [32] Rabie A Ramadan and Athanasios V Vasilakos. Brain computer interface: control signals review. *Neurocomputing*, 2016.
- [33] Saeid Sanei, Paris Smaragdis, Anthony TS Ho, Asoke K Nandi, and Jan Larsen. Guest editorial: Machine learning for signal processing. *Journal of Signal Processing Systems*, 79(2):113–116, 2015.
- [34] G. Schalk, D. J. McFarland, T. Hinterberger, N. Birbaumer, and J. R. Wolpaw. Bci2000: a general-purpose brain-computer interface (bci) system. *IEEE Transactions on Biomedical Engineering*, 51(6):1034–1043, June 2004.
- [35] Bernhard Scholkopf and Alexander J Smola. *Learning with kernels: support vector machines, regularization, optimization, and beyond*. MIT press, 2001.
- [36] Ali H Shoeb and John V Guttag. Application of machine learning to epileptic seizure detection. In *Proceedings of the 27th International Conference on Machine Learning (ICML-10)*, pages 975–982, 2010.
- [37] Tingxi Wen, Zhongnan Zhang, Wei Huang, Meihong Wang, and Chunfeng Li. Automatic epileptic seizure detection in eegs based on mf-dfa and svm. *Computerized Medical Imaging and Graphics*, 2016.

