

**CLASIFICACIÓN DE PATRONES DE ACELERACIÓN RELACIONADOS  
CON EL BRUXISMO NOCTURNO**

**TRABAJO DE GRADO No. 1511**

**ING. DAVID ARANGO ARANGO**

**DIRECTOR: PEDRO VIZCAYA PhD**

**PONTIFICIA UNIVERSIDAD JAVERIANA  
FACULTAD DE INGENIERIA  
MAESTRÍA EN INGENIERIA ELECTRÓNICA  
BOGOTA D.C.  
2016**

## TABLA DE CONTENIDO

TABLA DE CONTENIDO .....	2
LISTA DE FIGURAS .....	3
LISTA DE ANEXOS .....	3
1. INTRODUCCIÓN.....	4
2. MARCO TEÓRICO .....	6
2.1. Cepstro real.....	6
2.2. Distancia de Kullback-Leibler .....	6
2.3. Modelo de Mezcla de Gaussianas.....	6
2.4. Redes Neuronales Artificiales .....	8
3. ESPECIFICACIONES .....	9
3.1. Requerimientos.....	9
3.2. Descripción General .....	10
3.3. Sensado y Adquisición.....	10
3.4. Pre-segmentación y Transferencia .....	11
3.5. Almacenamiento .....	12
3.6. Alimentación .....	13
3.7. Sistema de Análisis y Procesamiento .....	13
4. DESARROLLO .....	13
4.1. Sistema de Adquisición y Almacenamiento de Datos.....	13
4.2. Construcción de la base de datos .....	15
4.3. Pre-procesamiento .....	15
4.4. Vector de Características .....	18
4.5. Modelo de Mezcla de Gaussianas.....	18
4.6. Distribución de los Componentes del GMM y Método de Clasificación 1 .....	18
4.7. Método de Clasificación 2: Red Neuronal.....	20
5. ANÁLISIS DE RESULTADOS .....	20
5.1. Pruebas Preliminares .....	20
5.2. Pruebas de desempeño: Red Neuronal .....	23
6. CONCLUSIONES.....	24
BIBLIOGRAFÍA.....	26
LISTA DE ANEXOS .....	27

## LISTA DE FIGURAS

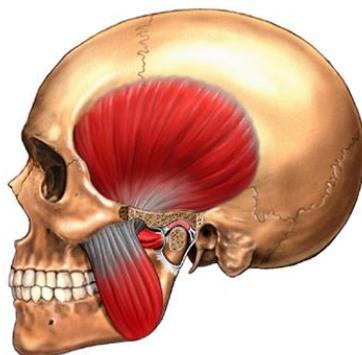
Figura 1. Esquema de articulación temporo-mandibular .....	4
Figura 2. Placa dental para el tratamiento del bruxismo.(Paesani et al., n.d.).....	4
Figura 3. Ejemplo de modelo de mezcla de gaussianas: 2 dimensiones y 4 componentes. (Duda, Hart, & Stork, 2000).....	7
Figura 4. Representación gráfica de una red neuronal.....	8
Figura 5. Diagrama de bloques del sistema .....	10
Figura 6. Kit acelerómetro - giróscopo GY-521 .....	11
Figura 7. Componentes principales del Arduino® Nano .....	12
Figura 8. Módulo adaptador Catalex® .....	12
Figura 9. Elaboración del sistema de adquisición y almacenamiento .....	14
Figura 10. Señales originales.....	16
Figura 11. Señales pre-procesadas .....	17
Figura 12. Respuesta en frecuencia del filtro pasa-altos .....	18
Figura 13. Distribución de componentes del GMM por clase. ....	19
Figura 14. Diagrama de flujo del proceso de clasificación.....	21
Figura 15: Pruebas comparativas iniciales de desempeño de los clasificadores.....	22
Figura 16: Prueba final de desempeño de la red neuronal.....	23

## LISTA DE ANEXOS

Anexo 1. Esquemático del kit acelerómetro GY-521 .....	27
Anexo 2. Esquemático del módulo adaptador para memoria micro SD .....	27

## 1. INTRODUCCIÓN

El bruxismo nocturno es un comportamiento que consiste en el rechinar o apretamiento de los dientes de manera involuntaria durante el sueño. La tensión producida puede ocasionar problemas en los músculos, tejidos y estructuras óseas, dolores de oído y de cabeza, lesiones en los dientes y trastornos en la articulación temporo-mandibular (ATM), que se presenta en la Figura 1.



*Figura 1. Esquema de articulación temporo-mandibular*

El diagnóstico del bruxismo nocturno y su estudio es un tema que ha demostrado ser difícil en el área de la odontología. Se realiza normalmente a partir de la evaluación de sus efectos sobre el paciente, entre ellos el desgaste dental, alteraciones del ATM, fracturas del esmalte, y dolor mio-facial. Sin embargo, estas técnicas no son del todo confiables, y peor aún, dependen de que el paciente haya sufrido las consecuencias de su condición. Las medidas correctivas más frecuentes frente al bruxismo involucran férulas dentales para la redistribución de las fuerzas y el reposicionamiento de los cóndilos, tratamientos con Botox, y hasta medicación psiquiátrica (McAuliffe, 2012).

Según estudios apoyados por la *Canadian Sleep Society*, el bruxismo nocturno afecta a un 8% de la población adulta y a un 14% de la población infantil en dicho país (G. J. Lavigne & Montplaisir, 1994). Otro estudio realizado en Sardinia, Italia, reporta que la presencia de la condición podría encontrarse en un 25% para ambos sexos en edades inferiores a los 60 años en dicha población (Melis & Abou-Atme, 2003). En cualquier caso, el bruxismo nocturno demuestra ser una afección que padece un grupo importante de la población humana.



*Figura 2. Placa dental para el tratamiento del bruxismo. (Paesani et al., n.d.)*

El análisis del bruxismo nocturno con base en señales biológicas se ha realizado en su mayor parte a partir de la polisomnografía (PSG). A pesar de que esta técnica es relativamente invasiva, ha permitido obtener información detallada acerca del comportamiento del paciente durante el sueño debido a la variedad de señales que se adquieren. En 2007, un estudio reportó que los eventos de bruxismo nocturno eran precedidos por cambios en el ritmo cardíaco y respiratorio (Gilles J. Lavigne et al., 2007). Otro estudio realizó un análisis comparativo de desempeño (Castroflorio, Deregibus, Bargellini, Debernardi, & Manfredini, 2014) entre un método automático de detección basado en EMG superficial de los maseteros complementado con ECG, y la detección manual por parte de un experto a partir del PSG. El estudio se realizó en 25 sujetos y la regla de clasificación del sistema basado en EMG y ECG fue la siguiente: Si el EMG del masetero en un momento dado correspondía al menos al 10% del CMV<sup>1</sup>, y el ritmo cardíaco aumentaba en al menos 20%, se clasificaba como bruxismo. El desempeño del sistema automático fue bastante alentador, con una sensibilidad del 92,3% y una especificidad del 91,6%.

El presente trabajo explora métodos para la detección del bruxismo en búsqueda de aproximaciones más apropiadas para al problema. En vista de que el odontólogo formula una férula dental<sup>2</sup> ante la sospecha de actividad bruxómana durante el sueño, se propone instrumentar dicho elemento y detectar las actividades nocturnas de interés a partir de los datos que éste genere. De esta manera se evitaría incurrir en el uso de artefactos adicionales que pueden generar una incomodidad mayor para el paciente.

En un trabajo similar (Martínez et al., 2010) se implementaron sensores de presión elaborados a partir de polímeros piezoeléctricos, (Fluoruro de Polivinilideno - PVDF) para la generación de las señales, con un rango de medición de 0 – 850 N, lo que constituye el rango de fuerza de oclusión de un ser humano promedio. Se implementó un filtro anti-sobrelapamiento de segundo orden, de topología Sallen-Key, con una frecuencia de corte de 9 Hz para la limitación del ancho de banda. El pre-procesamiento, la digitalización y las comunicaciones fueron realizados por un módulo WT32 de *BlueGiga*<sup>®</sup>, que integra un co-procesador DSP y capacidad de comunicación por Bluetooth. Las señales se enviaron posteriormente a un dispositivo móvil para su almacenamiento y observación.

En dicho proyecto, sin embargo, no se realizó ningún procesamiento matemático de las señales para buscar identificar los eventos, que es la motivación principal de esta investigación. Se pusieron a prueba diferentes técnicas de segmentación para buscar características diferenciadoras entre las señales de interés con el fin de desarrollar un sistema de apoyo inteligente para el diagnóstico y estudio del bruxismo nocturno. Es importante resaltar que los datos de estudio fueron generados a partir de pruebas de laboratorio efectuadas en un mismo sujeto en estado de vigilia, buscando reproducir los eventos de estudio del proyecto.

---

<sup>1</sup> Valor del EMG obtenido a partir del cierre máximo voluntario del paciente.

<sup>2</sup> Placa mio-relajante

## 2. MARCO TEÓRICO

### 2.1. Cepstro real

El *cepstro* fue propuesto como método de análisis de señales por primera vez como *cepstro de potencia* por Bogert en 1963 (Oppenheim & Schaffer, 2004). Particularmente, el *cepstro real* de una señal  $x(t)$  es la transformada inversa de Fourier del logaritmo de la magnitud de la transformada de Fourier de la señal:

$$IFT\{\log\{|FT\{x(t)\}|\}\}$$

El análisis cepstral es una técnica ampliamente utilizada en análisis de voz para determinar el timbre, ya que tiene el efecto de resaltar las frecuencias más dominantes por el efecto del logaritmo en la magnitud del espectro, diezmando las bandas laterales. El cepstro es llamado a veces “*el espectro del espectro*”, ya que refleja la forma o envolvente del espectro. Sin embargo, su dominio es en el tiempo y no la frecuencia por definición.

El análisis cepstral se ha empleado también para separar (“deconvolucionar”) la respuesta del sistema de la señal, cuando aquella se ve reflejada principalmente en la envolvente del espectro, que se transforman en las primeras componentes del cepstro. En esta misma aproximación, el cepstro se emplea para reducir la dimensionalidad del espacio del espectro (que es la misma del espacio original), y así se le usa en este desarrollo.

### 2.2. Distancia de Kullback-Leibler

La *Distancia de Kullback-Leibler*, también conocida como *Divergencia de Kullback-Leibler*, es una medida de divergencia entre dos distribuciones de probabilidad  $P$  y  $Q$ . Aunque se le llama distancia, no es en realidad una métrica válida, ya que no es simétrica de  $P$  a  $Q$ . Para distribuciones discretas se define como

$$\sum_{i=-\infty}^{\infty} P(x_i) \log \frac{P(x_i)}{Q(x_i)}$$

Esta medida fue propuesta por Solomon Kullback y Richard Leibler in 1951 y tiene importantes aplicaciones, tanto en estadística como en Teoría de la Información. En la práctica,  $P$  representa la distribución de probabilidad “verdadera”, o de referencia, mientras que  $Q$  representa la distribución que se desea comparar (Cover & Thomas, 2005). Con el fin de obtener una métrica válida, se suele sumar la distancia de  $P$  a  $Q$  con la distancia de  $Q$  a  $P$ , lo que resulta en una medida conmutativa.

### 2.3. Modelo de Mezcla de Gaussianas

El Modelo de Mezcla de Gaussianas, o GMM por sus siglas en inglés, es un método de clasificación no-supervisada utilizado en Análisis de Conglomerados, ó *clusters* (McLachlan & Basford, 1988). En general, todos los métodos de clasificación generan agrupaciones de manera que los objetos en cada grupo sean lo más similares entre sí, y los objetos en los diferentes grupos lo más distintos posible. La medida de similaridad depende del método de agrupación.

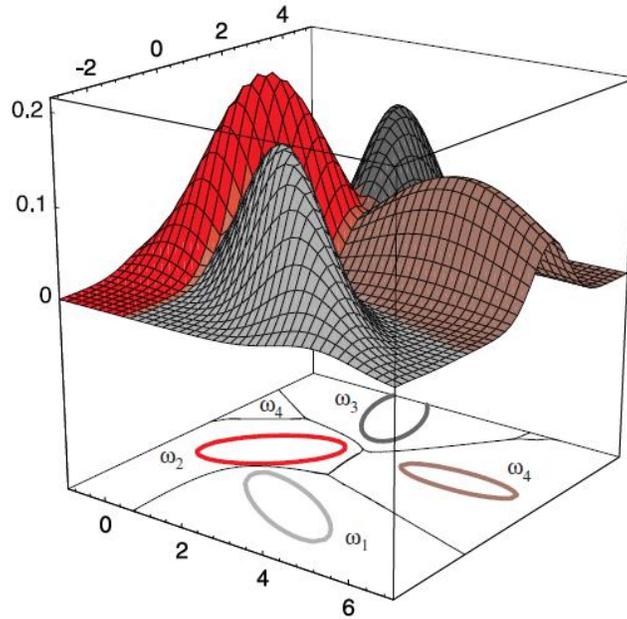


Figura 3. Ejemplo de modelo de mezcla de gaussianas: 2 dimensiones y 4 componentes. (Duda, Hart, & Stork, 2000)

Los GMM pertenecen a los modelos probabilísticos conocidos como *Modelos de Mezclas Finitas*. Dichos modelos asumen que se toman datos de una manera i.i.d.<sup>3</sup>, y que pertenecen a una distribución  $p(\underline{x})$  subyacente. Se asume además que  $p(\underline{x})$  está definida como una mezcla finita de  $K$  componentes:

$$p(\underline{x}|\Theta) = \sum_{k=1}^K \alpha_k p_k(\underline{x}|z_k, \theta_k)$$

donde

- $p_k$  representa el componente  $k$  de la mezcla con parámetros  $\theta_k$
- $\alpha_k$  es el peso del componente  $k$  en la mezcla, representando la probabilidad de que un punto  $\underline{x}$  pertenezca a la componente.
- Los parámetros completos de la mezcla están dados por:

$$\Theta = \{\alpha_1, \dots, \alpha_K, \theta_1, \dots, \theta_K\}$$

Los ponderaciones de pertenencia de cada dato a cada una de las componentes se calculan de la siguiente forma:

<sup>3</sup> Independiente e idénticamente distribuida

$$w_{ik} = p(z_{ik} = 1 | \underline{x}_i, \Theta) = \frac{p_k(\underline{x}_i | z_k, \theta_k) \cdot \alpha_k}{\sum_{m=1}^K p_m(\underline{x}_i | z_m, \theta_m) \cdot \alpha_m}, \quad 1 \leq k \leq K, \quad 1 \leq i \leq N$$

En el caso de la GMM, se asume que los componentes de la mezcla son gaussianas multivariadas:

$$p_k(\underline{x} | \theta_k) = \frac{1}{(2\pi)^{d/2} |\Sigma_k|^{1/2}} e^{-\frac{1}{2}(\underline{x} - \underline{\mu}_k)^t \Sigma_k^{-1} (\underline{x} - \underline{\mu}_k)}$$

con sus respectivos vectores de medias y matrices de covarianzas como parámetros:

$$\theta_k = \{ \underline{\mu}_k, \Sigma_k \}$$

El algoritmo de *Maximización de la Esperanza (EM)* es el procedimiento que se ejecuta para generar la GMM. Se inicia con parámetros iniciales aleatorios para la distribución y se actualizan hasta lograr convergencia. Cada iteración del algoritmo consta de dos pasos básicos, análogos al método de las k medias: optimización del modelo y reclasificación de las muestras.

## 2.4. Redes Neuronales Artificiales

Las redes neuronales artificiales son un modelo computacional de aprendizaje supervisado muy utilizado en problemas de clasificación. La red pretende aproximarse al funcionamiento cerebral para resolver problemas, contando con unidades neuronales entrelazadas que se asemejan a la forma como se conectan las neuronas biológicas por medio del axón (Rojas, 1996). Cada neurona puede tener una función sumatoria que combina los valores de todas sus entradas, así como un umbral, o función limitadora, que debe superarse antes de propagarse a las siguientes en la red. Estos sistemas son muy adaptativos, y por lo tanto muy populares en problemas de difícil solución.

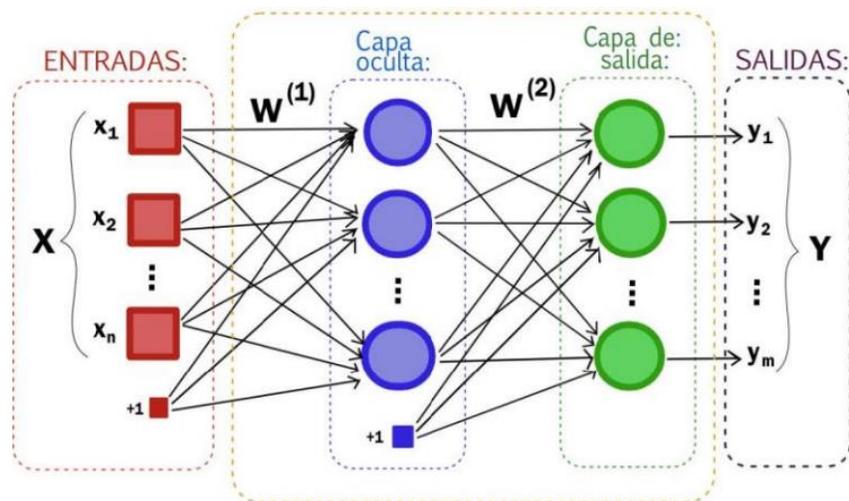


Figura 4. Representación gráfica de una red neuronal<sup>4</sup>

<sup>4</sup> Fuente: [http://ceres.ugr.es/~alumnos/esclas/imagenes/index\\_img\\_4.jpg](http://ceres.ugr.es/~alumnos/esclas/imagenes/index_img_4.jpg)

Normalmente, las redes consisten de varias capas que se recorren de adelante hacia atrás. Su funcionamiento está basado en los números reales, y cada neurona entrega valores entre cero y uno. Algo interesante de estos sistemas es que su éxito para aprender es impredecible. Para entrenarlas suelen requerirse varios ciclos de interacción.

Las redes neuronales están definidas normalmente por tres tipos de parámetros:

1. Los patrones de interconexión entre las capas
2. El proceso de aprendizaje para la actualización de los pesos ( $w$ ) de las interconexiones.
3. La función de activación que convierte sus entradas (de diferentes pesos) en su salida.

La función de red está definida por una composición de otras funciones, que a su vez están definidas por otras funciones. Este modelo puede ser representado por una estructura de red con flechas que ilustran las dependencias entre las variables. Una composición muy utilizada es la **Suma Ponderada No-Lineal**. Matemáticamente:

$$f(x) = K \left( \sum_i w_i g_i(x) \right)$$

Donde  $K$  es conocida como la **Función De Activación**, que suele ser una función predefinida, como por ejemplo la *Tangente Hiperbólica*.

### 3. ESPECIFICACIONES

#### 3.1.Requerimientos

Uno de los objetivos del proyecto es construir un sistema de adquisición y almacenamiento de datos provenientes de algún transductor que refleje los movimientos que se desean clasificar. El sensor debe tener dimensiones apropiadas para ser embebido en una férula dental que pueda utilizar el sujeto de prueba, y reflejar los movimientos con suficiente sensibilidad.

El sensor también debe tener la capacidad de comunicarse de manera serial con un microcontrolador ubicado fuera de boca a través de cables delgados para reducir la incomodidad del sujeto de prueba. Este se encargará de iniciar la rutina de captura y almacenamiento una vez detectada alguna actividad de suficiente intensidad. La tasa de muestreo del sistema será la más alta posible, y será limitada por la velocidad del microcontrolador para leer y almacenar los datos en la unidad de almacenamiento.

El sistema debe ser capaz de almacenar los datos en una memoria SD para ser fácilmente descargados a un computador y ser procesados fuera de línea por el sistema de procesamiento y clasificación. Dicho sistema, que constituye la parte fundamental del proyecto, será desarrollado en MATLAB.

El sistema debe tener la capacidad de ser alimentado por batería, y ser en general autónomo, con el fin de que el paciente pueda moverse libremente durante el sueño. La autonomía no debe ser inferior a 8 horas con el fin de capturar suficientes datos de una sesión completa de sueño. A pesar de que en este proyecto todos los movimientos son realizados en laboratorio, se pretende tener una primera

aproximación a un dispositivo de adquisición y almacenamiento que permita estudiar la actividad nocturna en pacientes reales.

### 3.2.Descripción General

En la Figura 5 se presenta el diagrama de bloques del sistema:

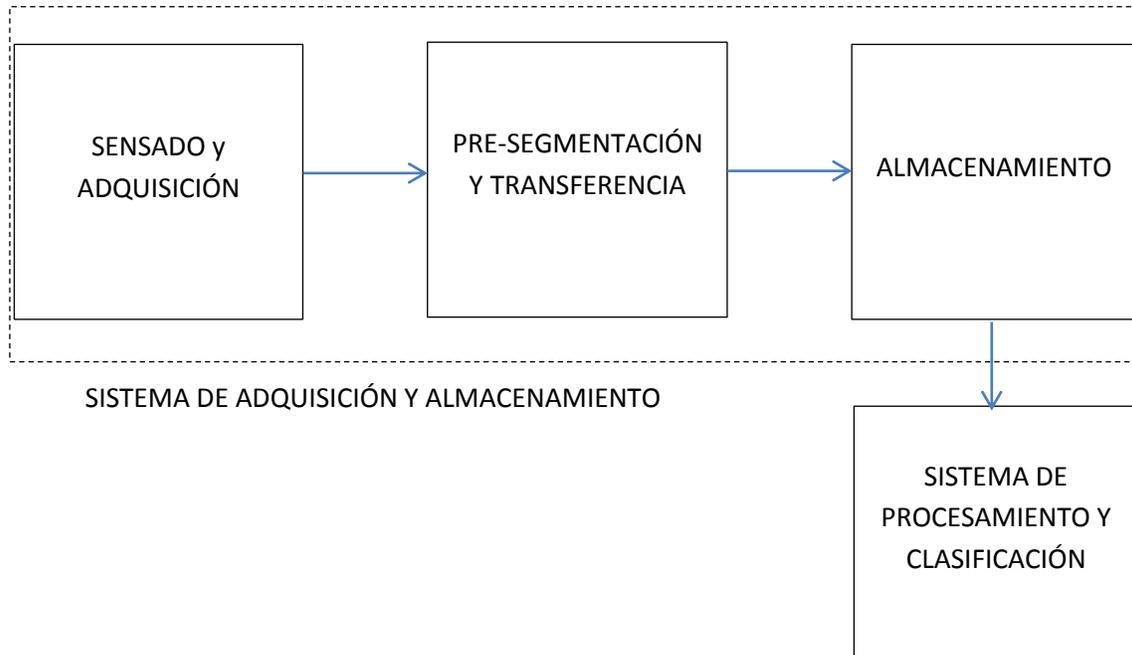


Figura 5. Diagrama de bloques del sistema

### 3.3.Sensado y Adquisición

El sensor que se eligió para generar las señales fue un sensor digital<sup>5</sup> que integra un acelerómetro de 3 ejes, un giróscopo, y un sensor de temperatura. En este proyecto, sólo se utilizaron los datos provenientes del acelerómetro, que cuenta con las siguientes especificaciones básicas:

Resolución del ADC:	16 bits
Voltaje de operación:	2,3 – 3,4 V
Respuesta del filtro <i>antialiasing</i> del acelerómetro:	260 Hz
Tasa de muestreo:	1 kHz
Rango dinámico:	+/- 2g
Consumo eléctrico	500 uA

Tabla 1: Especificaciones del acelerómetro digital MPU6050 de InvenSense®

<sup>5</sup> MPU6050 de InvenSense®

El sensor utilizado viene integrado en un kit listo para ser utilizado, como se puede ver en la Figura 6 . El esquemático se encuentra en el Anexo 1. Las dimensiones de la PCB son 2.1 cm x 1.6 cm x 0.3 cm.



Figura 6. Kit acelerómetro - giróscopo GY-521

### 3.4.Pre-segmentación y Transferencia

Con el fin de pre-segmentar los datos y posteriormente transferirlos a la unidad de almacenamiento, se utilizó un kit de prototipado *Arduino® Nano*, que cuenta con las siguientes especificaciones:

MCU:	ATMEL® ATMEGA328P
Arquitectura del MCU:	RISC, 8 bits
Voltaje de operación:	1,8 – 5,5 V
Memoria de programa:	16 kB, Flash
Memoria de almacenamiento:	1 kB, EEPROM
Comunicación serial:	USART
Comunicación periférica:	SPI, I <sup>2</sup> C
Fuente de oscilación:	Cristal, 16 MHz

Tabla 2: Especificaciones del *Arduino® Nano*

La memoria del microcontrolador no fue utilizada para almacenar los datos dado que su capacidad era insuficiente para este propósito. En la *Figura 7* se puede observar el kit y sus principales componentes:

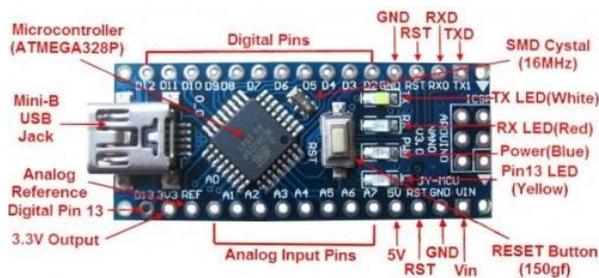


Figura 7. Componentes principales del Arduino® Nano<sup>6</sup>

Para evitar incurrir en almacenamiento y consumo eléctrico innecesarios, el sistema se debería encargar de pre-segmentar los datos, capturando únicamente señales que pudieran corresponder a posibles eventos de bruxismo.

Las señales provenientes del sensor son monitoreadas todo el tiempo, pero no son grabadas inicialmente. Tan pronto un pico en la señal exceda un umbral específico, el sistema graba los siguientes 10 segundos para ser analizados. El umbral es determinado de manera experimental, observando la amplitud de las señales relacionadas con el bruxismo, y de las señales provenientes del sujeto en reposo.

### 3.5. Almacenamiento

Se optó por utilizar un módulo adaptador de tarjeta micro SD para integrarlo con el Arduino y lograr la capacidad de almacenamiento requerida por la aplicación.



Figura 8. Módulo adaptador Catalex®

La memoria SD se eligió como dispositivo de almacenamiento por su alta capacidad así como por la facilidad de ser retirada del dispositivo e insertada en un computador. Esta característica elimina la necesidad de desarrollos adicionales para extraer los datos del dispositivo, y facilita el procedimiento para el usuario. El esquemático de este se presenta en el Anexo 2.

<sup>6</sup> Fuente: <http://www.tronicsbd.com/product/arduino-nano-v3-0/>

### **3.6.Alimentación**

Con el fin de lograr un alto nivel de autonomía del sistema de captura y almacenamiento, éste podrá ser alimentado por una batería de 9v en estudios futuros. El *Arduino*<sup>®</sup> integra un convertidor de voltaje conmutado que ajusta la alimentación a los 3.3v requeridos por el circuito, así que no es necesario realizar acondicionamientos adicionales.

En este proyecto, sin embargo, el dispositivo fue alimentado con 5V a través del puerto USB del PC, ya que los movimientos fueron realizados en laboratorio y no fue necesario un dispositivo autónomo.

### **3.7.Sistema de Análisis y Procesamiento**

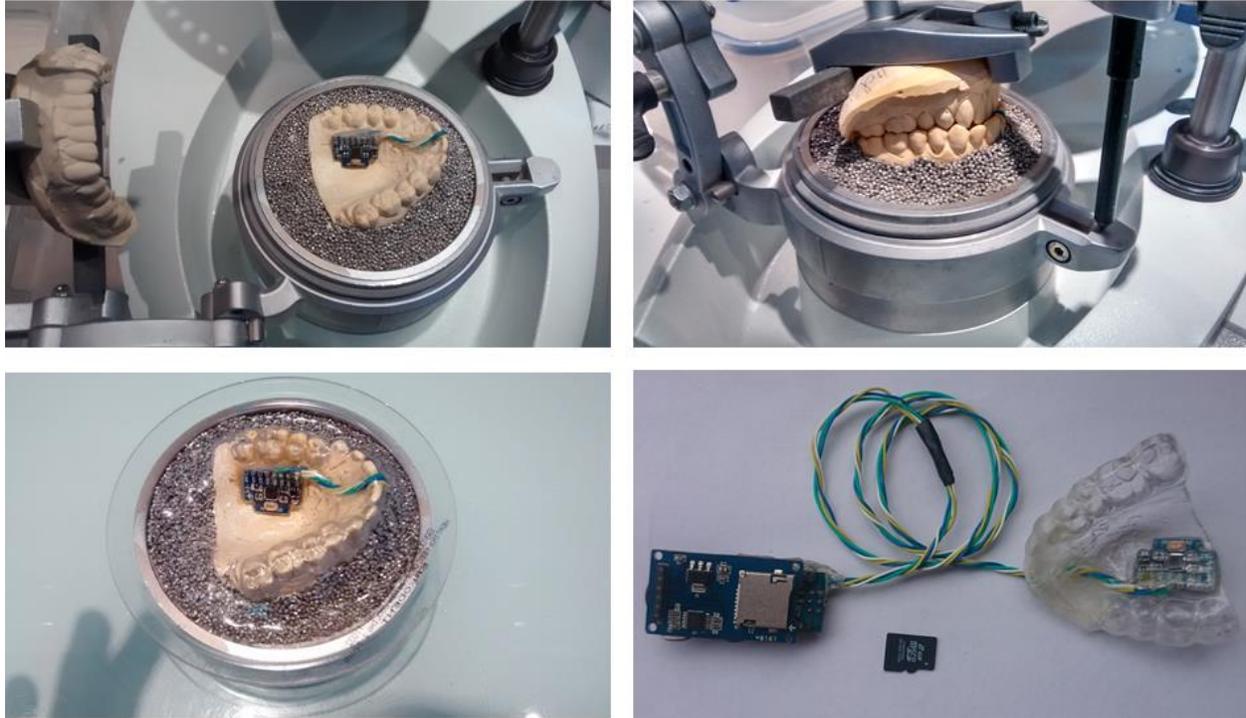
El sistema de análisis y procesamiento fue desarrollado en *MATLAB*<sup>®</sup>. Los objetivos de este desarrollo son los siguientes:

- Acondicionamiento de las señales.
- Extracción de características de las señales.
- Clasificación de los datos a partir de modelos.

## **4. DESARROLLO**

### **4.1.Sistema de Adquisición y Almacenamiento de Datos**

Con el fin de generar los datos de estudio, se construyó una férula dental instrumentada con un acelerómetro digital que pudiera captar los movimientos provenientes de los distintos patrones de comportamiento de interés. El acelerómetro fue embebido dentro del acrílico de la placa para aislarlo de la saliva, evitando así fallas en el dispositivo y posibles problemas de salud para el sujeto de prueba. A pesar de que en este proyecto los datos fueron obtenidos a partir de experimentos de laboratorio, el dispositivo fue diseñado con el propósito de ser implementado en un ambiente real, y por lo tanto busca cumplir con los requerimientos mínimos de almacenamiento y autonomía necesarios para realizar otros estudios en el futuro.



*Figura 9. Elaboración del sistema de adquisición y almacenamiento*

El acelerómetro digital se configuró para comunicarse de manera serial con el *Arduino*<sup>®</sup> a través del bus  $I^2C$ <sup>7</sup>, que se encarga de leer el valor de los datos correspondientes a las aceleraciones experimentadas por la férula. Debido a que los datos generados por el acelerómetro tienen una resolución de 16 bits y la arquitectura del microcontrolador es de 8 bits, el sistema debe leer los datos en dos etapas: primero el byte más significativo, y luego el menos significativo, para luego combinarlos en un solo dato. Esto genera una carga operacional mayor para el dispositivo.

La tasa de muestreo total del sistema de adquisición resultó ser de alrededor de 330 Hz con los tres canales, y de 1 kHz con un solo canal. Se tomó la decisión de adquirir un solo canal<sup>8</sup> inicialmente con el fin de mantener la máxima tasa posible y obtener información de una banda de frecuencias mayor. El ancho de banda de las señales va de 160 a 260 Hz.

Se estableció que el sistema debía contar con una capacidad mínima de almacenamiento de 30 minutos por noche para capturar suficientes datos, lo que arroja los siguientes requerimientos de capacidad:

**REQUERIMIENTOS DE ALMACENAMIENTO:** 30 min x 60 seg x 1 kHz x 1 canal x 2 Bytes = 3,6 MB

Se concluyó entonces que una memoria SD de 2 GB sería más que suficiente para el almacenamiento de los datos. De esta manera, si el sistema de adquisición es utilizado en un ambiente real, podrá

<sup>7</sup> *Inter-integrated circuit (I<sup>2</sup>C).*

<sup>8</sup> Canal correspondiente al eje x del acelerómetro.

almacenar los datos de múltiples sesiones sin necesidad de ser descargados diariamente. Las comunicaciones entre el microcontrolador y la memoria SD se realizaron a través del bus *SPI*<sup>9</sup>.

## 4.2. Construcción de la base de datos

Se determinó que los eventos que ocurren durante el sueño que nos interesa clasificar inicialmente en este proyecto son los siguientes:

- Patrones de bruxismo:
  - Apretamiento de los dientes con deslizamiento en dirección frontal
  - Apretamiento de los dientes con deslizamiento lateral
  - Chasquidos de dientes
- Paso de saliva

Para la construcción de la base de datos se realizó el siguiente procedimiento:

Primero, el sujeto se colocó la férula instrumentada en el maxilar superior con el sistema de adquisición y almacenamiento conectado al puerto USB de un computador para su alimentación. Luego, el sujeto adquirió alrededor de 1 minuto de cada patrón de estudio realizando los mismos movimientos de manera repetitiva. Los movimientos correspondientes a “Bruxismo Frontal” se realizaron apretando los dientes y deslizando los de adelante hacia atrás. Estos movimientos son conocidos como “*protrusiones*” en odontología. Los movimientos correspondientes a “Bruxismo Lateral” se realizaron de manera similar, pero deslizando los dientes de un lado al otro. A estos se les conoce con el nombre de “*lateralidades*”. El último patrón relacionado con el bruxismo fue el “Chasquido”. Estos datos se adquirieron golpeando suavemente los dientes al cerrar la boca.

La realidad es que existen otros eventos que serían captados inevitablemente por el sistema de adquisición durante el sueño. Dentro de estos eventos se encuentran los ronquidos, los pasos de saliva, la tos, e incluso la misma respiración. En este proyecto no se busca clasificarlos, pero sí es importante poder descartarlos de alguna manera. Como una primera aproximación a este problema, se incluyó el paso de saliva debido a que suele involucrar un leve golpe entre los dientes al cerrar la boca, y debería ser el más difícil de separar. Sin embargo, en futuras investigaciones se deberían incluir la totalidad de los posibles movimientos.

Finalmente, los datos fueron descargados en un computador desde la memoria micro SD para ser analizados y procesados en *MATLAB*<sup>®</sup>.

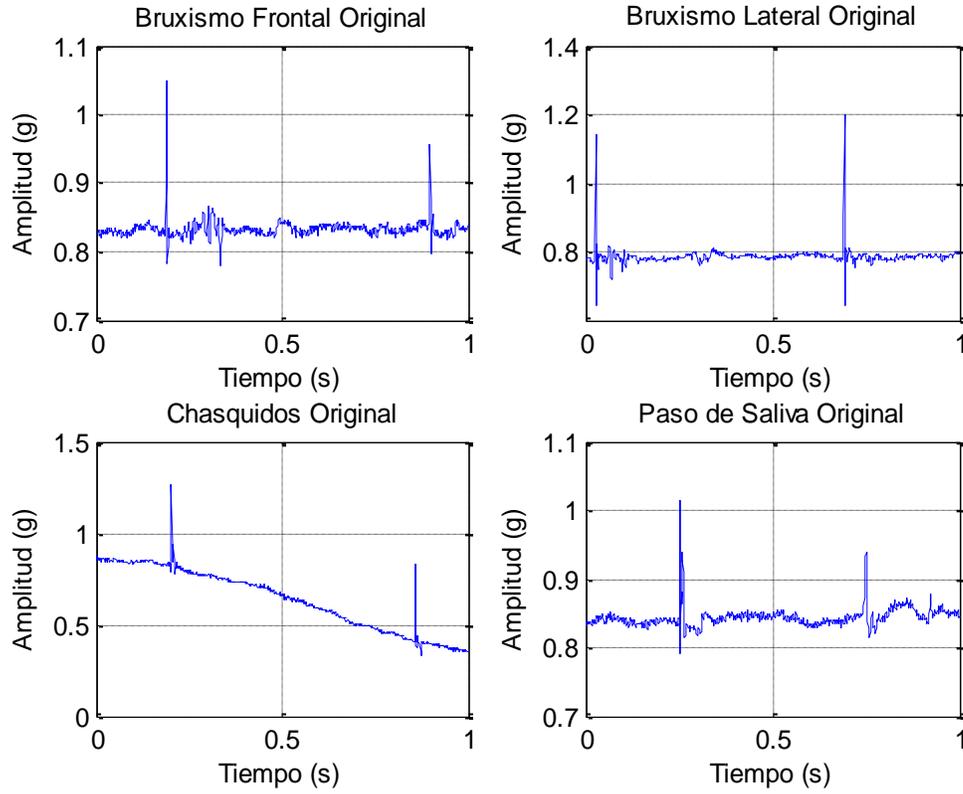
## 4.3. Pre-procesamiento

Debido a que las señales provenientes del acelerómetro sufren cambios en su nivel DC al cambiar la posición del sensor, se implementó como primera medida un filtro digital pasa-altos para eliminar este efecto. Sin embargo, este fenómeno puede ser utilizado en el futuro para obtener más información relacionada con el sueño del paciente, como por ejemplo las posiciones del cuerpo en momentos específicos o el grado de actividad nocturna.

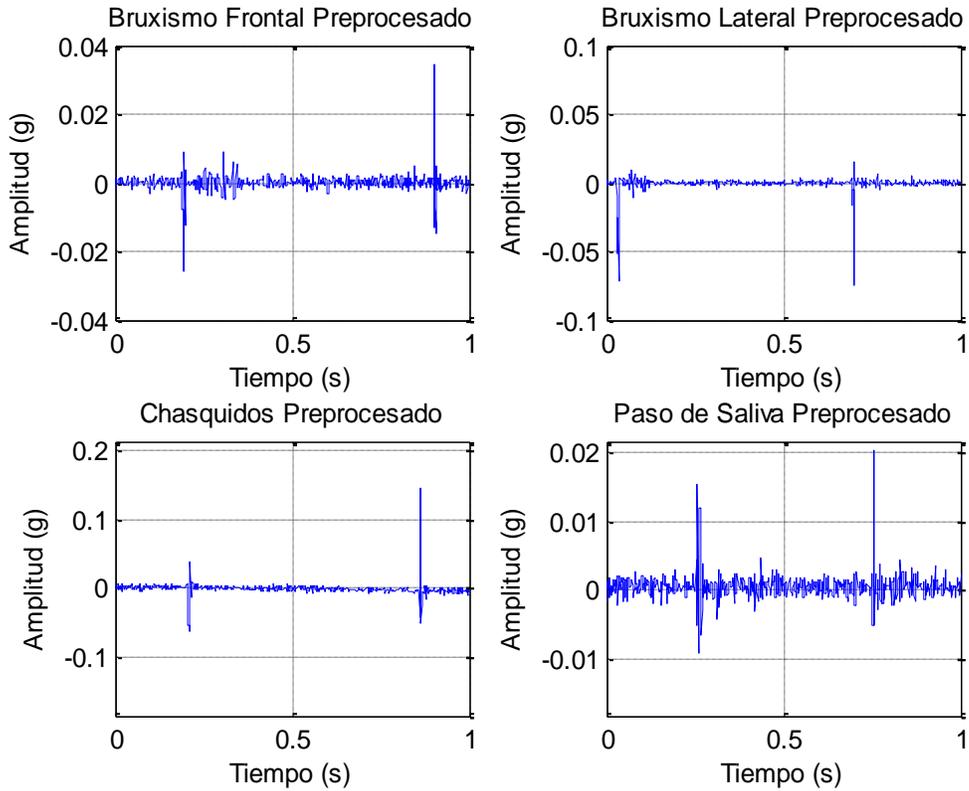
---

<sup>9</sup> Interface serial periférica.

Adicionalmente, se aplicó un filtro de mediana de orden 3 con el fin de eliminar datos atípicos y se restaron las medias, ya que el filtro pasa-altos aplicado tiene una ganancia de -40 dB en frecuencia cero. En la Figura 10 y Figura 11 se puede observar el efecto del pre-procesamiento sobre las señales.



*Figura 10. Señales originales*



*Figura 11. Señales pre-procesadas*

El filtro pasa-altos aplicado sobre las señales tiene las siguientes especificaciones:

- Tipo de filtro: FIR, Pasa-altos
- Orden: 10
- Frecuencia de corte: 160 Hz a -6 db y frecuencia de atenuación 60 Hz (-20dB).

La respuesta en frecuencia se muestra en la Figura 12:

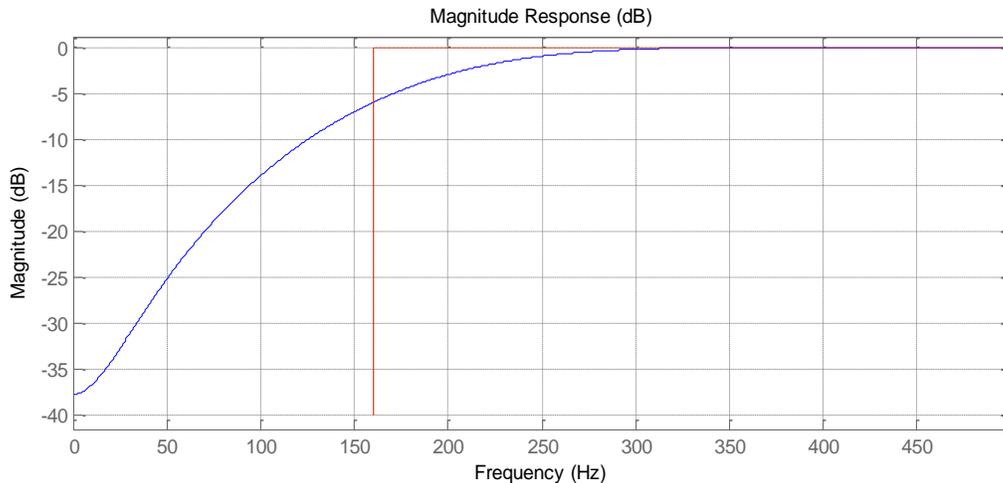


Figura 12. Respuesta en frecuencia del filtro pasa-altos

#### 4.4. Vector de Características

Se dividieron las señales en ventanas sobrelapadas al 50% de 100 milisegundos con el fin de analizar las señales en segmentos cortos. La ventana fue escogida buscando un compromiso entre los eventos más largos (patrones de deslizamiento frontal y lateral), y los eventos más cortos (chasquidos de dientes).

Se calculó el cepstro real de los segmentos de las señales con el fin de utilizar algunos de sus coeficientes para construir un vector de características. Debido a que los patrones de estudio poseen características dinámicas importantes, se calcularon también las primeras diferencias cepstrales de los segmentos, y se incluyeron como características en el vector. Con el fin de mantener una dimensionalidad adecuada para un modelo posterior, se tomaron en cuenta los primeros 12 coeficientes. No se tuvo en cuenta el primer coeficiente, directamente relacionado con la energía de la señal.

#### 4.5. Modelo de Mezcla de Gaussianas

La base de datos se partió de la siguiente manera: 40% para entrenamiento, y 60% para pruebas. La partición se realizó de esta manera debido a que posteriormente se extraerían tramas aleatorias de los datos de pruebas y era importante mantener su independencia. A continuación se entrenó un Modelo de Mezcla de Gaussianas limitado a 6 componentes con los datos de entrenamiento. Este valor se determinó experimentalmente observando el comportamiento del AIC<sup>10</sup>, que pondera la complejidad del modelo y la verosimilitud, evitando el sobre-ajuste. La matriz de covarianza del modelo fue diagonalizada con el fin de mantener una dimensionalidad adecuada para el modelo.

#### 4.6. Distribución de los Componentes del GMM y Método de Clasificación 1

Los datos de entrenamiento de las diferentes clases no fueron clasificados en los componentes del modelo de manera que pudieran separarse individualmente. Sin embargo, se observó que la distribución de los componentes para las diferentes clases a mediano plazo sí presentaba diferencias,

<sup>10</sup> Criterio de Información de Akaike.

abriendo la posibilidad de clasificar conjuntos de segmentos (en contraste con segmentos aislados). Este comportamiento es coherente con la hipótesis de la existencia de un comportamiento estadístico estacionario distinto de cada clase a mediano plazo que las distingue. La Figura 13 muestra las diferencias entre la distribución de los componentes para un entrenamiento particular del modelo.

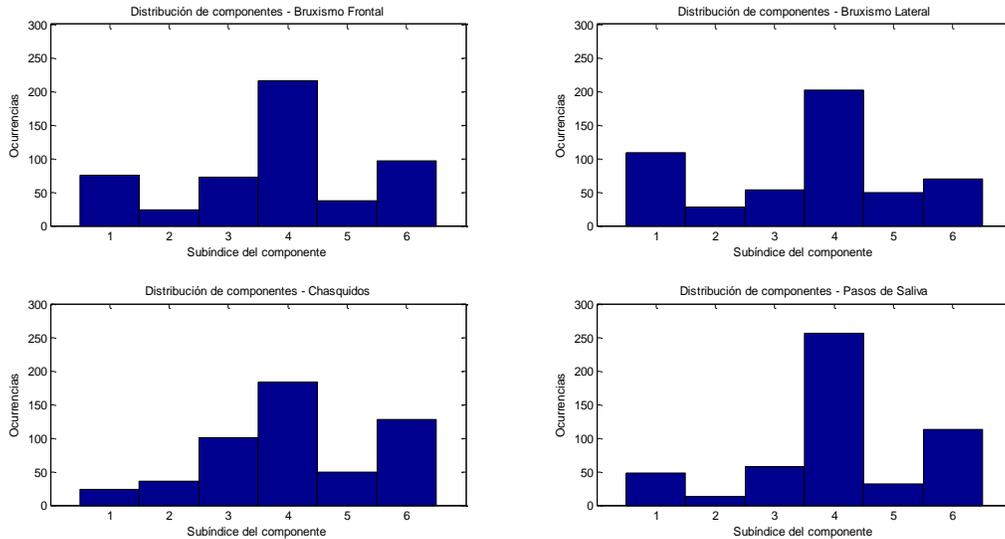


Figura 13. Distribución de componentes del GMM por clase.

Se propuso entonces el siguiente método de clasificación:

- Calcular histogramas de frecuencia de los índices de los componentes del modelo GMM, tanto del conjunto de entrenamiento, como del conjunto de validación, conociendo los rótulos de los datos.
- Normalizar los histogramas con el fin de obtener distribuciones de probabilidad válidas.
- Clasificar los conjuntos de datos a partir de la distancia de Kullback-Leibler<sup>11</sup> (en adelante distancia KL) desde su distribución a las distribuciones de referencia.
- Se aplicó la siguiente regla de clasificación: el conjunto de datos se clasifica con el rótulo de la distribución de referencia que presente la distancia mínima a su propia distribución.

En vista de que la distancia KL no corresponde a una verdadera métrica<sup>12</sup>, se resolvió sumando la distancia entre las dos distribuciones P y Q en ambas direcciones para hacerla simétrica: de P a Q, y de Q a P.

La distancia de Kullback-Leibler presenta problemas numéricos cuando la probabilidad en un punto de la distribución Q es cero ( $\log(0)$  y división por 0). Para resolver este problema, le asignamos un valor muy pequeño a dichos puntos de la función ( $\epsilon$ ).

<sup>11</sup> Medida de distancia entre dos elementos de un conjunto.

<sup>12</sup> No cumple con la desigualdad del triángulo, la distancia de Q a P es diferente a la distancia de P a Q.

## 4.7.Método de Clasificación 2: Red Neuronal

Como método alternativo de clasificación se utilizó una red neuronal para clasificar los conjuntos de eventos según la distancia KL que presentaran desde su distribución de componentes hasta las distribuciones de referencia. Se utilizó la GUI<sup>13</sup> para redes neuronales de *MATLAB*<sup>®</sup> para configurar y ejecutar la red.

## 5. ANÁLISIS DE RESULTADOS

### 5.1.Pruebas Preliminares

Inicialmente, se buscaron parámetros adecuados para entrenar el GMM, ya que es la base de ambos métodos de clasificación. A partir de la experimentación, se determinaron parámetros suficientes para construir un modelo de manera que el método de clasificación 1 presentara un desempeño aceptable y compararlo con el método alternativo. Los parámetros utilizados para esta prueba inicial fueron los siguientes:

- Ventana para el cálculo del cepstro: 100 ms, 50% de solapamiento
- Número de coeficientes cepstrales: 12 ( y sus primeras diferencias)
- Componentes del GMM: 6
- Número de tramas para el cálculo de las distribuciones de prueba: 78
- Duración de las señales de prueba: 100 ms x 78 tramas x 0.5 solapamiento = 3,9 segundos

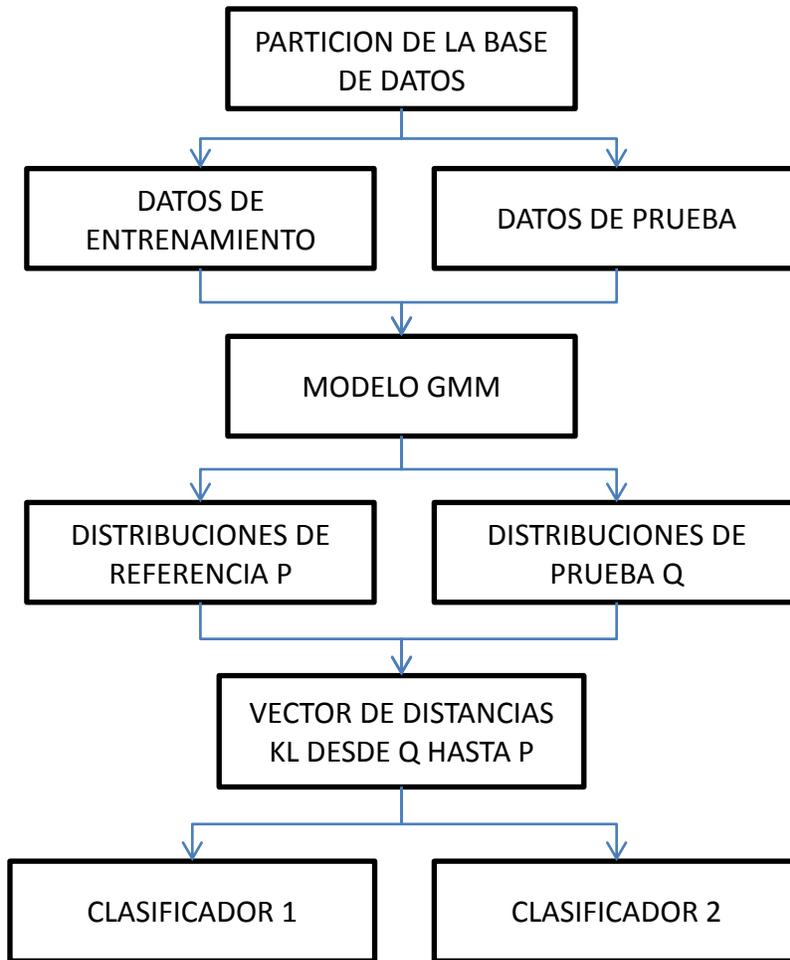
La configuración de la red neuronal fue la siguiente:

- 2 neuronas en su capa oculta.
- Datos para entrenamiento: 70%.
- Datos para validación: 15%.
- Datos para pruebas: 15%.

Posteriormente se comparó el desempeño de ambos clasificadores de la siguiente manera:

---

<sup>13</sup> Interfaz gráfica de usuario.



*Figura 14. Diagrama de flujo del proceso de clasificación.*

1. Entrenamiento del GMM con el 40% de la base de datos, tomados aleatoriamente.
2. Clasificación de cada punto de los datos de entrenamiento según los componentes de la mezcla por parte del modelo.
3. Generación de distribuciones de referencia de cada una de las 4 clases a partir de los datos de entrenamiento.
4. Extracción de 100 tramas de las señales de prueba de manera aleatoria.
5. Clasificación de los puntos de las tramas por parte del modelo y generación de las distribuciones de prueba.
6. Cálculo de la distancia KL desde cada distribución de prueba hasta las 4 distribuciones de referencia.
7. Clasificación de las distribuciones por parte de los clasificadores 1 y 2.

En la Figura 15 se observan las matrices de confusión obtenidas en dos de las pruebas realizadas:

CLASIFICADOR 1	CLASIFICADOR 2																																																																																																																				
<p>MATRIZ DE CONFUSION DE ENTRENAMIENTO</p> <table border="1"> <tr><td>97</td><td>3</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>100</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>0</td><td>100</td><td>0</td></tr> <tr><td>0</td><td>0</td><td>20</td><td>80</td></tr> </table> <p>EFFECTIVIDAD: 94,25%</p>	97	3	0	0	0	100	0	0	0	0	100	0	0	0	20	80	<div style="display: flex; justify-content: space-around;"> <div> <p>Training Confusion Matrix</p> <table border="1"> <tr><td>64</td><td>0</td><td>0</td><td>0</td><td>100%</td></tr> <tr><td>0</td><td>73</td><td>0</td><td>0</td><td>100%</td></tr> <tr><td>0</td><td>0</td><td>73</td><td>3</td><td>96.1%</td></tr> <tr><td>0</td><td>0</td><td>0</td><td>67</td><td>100%</td></tr> <tr><td>100%</td><td>100%</td><td>100%</td><td>95.7%</td><td>98.9%</td></tr> </table> </div> <div> <p>Validation Confusion Matrix</p> <table border="1"> <tr><td>16</td><td>0</td><td>0</td><td>0</td><td>100%</td></tr> <tr><td>0</td><td>14</td><td>0</td><td>0</td><td>100%</td></tr> <tr><td>0</td><td>0</td><td>16</td><td>0</td><td>100%</td></tr> <tr><td>0</td><td>0</td><td>0</td><td>14</td><td>100%</td></tr> <tr><td>100%</td><td>100%</td><td>100%</td><td>100%</td><td>100%</td></tr> </table> </div> </div> <div style="display: flex; justify-content: space-around; margin-top: 10px;"> <div> <p>Test Confusion Matrix</p> <table border="1"> <tr><td>20</td><td>0</td><td>0</td><td>0</td><td>100%</td></tr> <tr><td>0</td><td>13</td><td>0</td><td>0</td><td>100%</td></tr> <tr><td>0</td><td>0</td><td>11</td><td>2</td><td>84.6%</td></tr> <tr><td>0</td><td>0</td><td>0</td><td>14</td><td>100%</td></tr> <tr><td>100%</td><td>100%</td><td>100%</td><td>87.5%</td><td>96.7%</td></tr> </table> </div> <div> <p>All Confusion Matrix</p> <table border="1"> <tr><td>100</td><td>0</td><td>0</td><td>0</td><td>100%</td></tr> <tr><td>0</td><td>100</td><td>0</td><td>0</td><td>100%</td></tr> <tr><td>0</td><td>0</td><td>100</td><td>5</td><td>95.2%</td></tr> <tr><td>0</td><td>0</td><td>0</td><td>95</td><td>100%</td></tr> <tr><td>100%</td><td>100%</td><td>100%</td><td>95.0%</td><td>98.8%</td></tr> </table> </div> </div>	64	0	0	0	100%	0	73	0	0	100%	0	0	73	3	96.1%	0	0	0	67	100%	100%	100%	100%	95.7%	98.9%	16	0	0	0	100%	0	14	0	0	100%	0	0	16	0	100%	0	0	0	14	100%	100%	100%	100%	100%	100%	20	0	0	0	100%	0	13	0	0	100%	0	0	11	2	84.6%	0	0	0	14	100%	100%	100%	100%	87.5%	96.7%	100	0	0	0	100%	0	100	0	0	100%	0	0	100	5	95.2%	0	0	0	95	100%	100%	100%	100%	95.0%	98.8%
97	3	0	0																																																																																																																		
0	100	0	0																																																																																																																		
0	0	100	0																																																																																																																		
0	0	20	80																																																																																																																		
64	0	0	0	100%																																																																																																																	
0	73	0	0	100%																																																																																																																	
0	0	73	3	96.1%																																																																																																																	
0	0	0	67	100%																																																																																																																	
100%	100%	100%	95.7%	98.9%																																																																																																																	
16	0	0	0	100%																																																																																																																	
0	14	0	0	100%																																																																																																																	
0	0	16	0	100%																																																																																																																	
0	0	0	14	100%																																																																																																																	
100%	100%	100%	100%	100%																																																																																																																	
20	0	0	0	100%																																																																																																																	
0	13	0	0	100%																																																																																																																	
0	0	11	2	84.6%																																																																																																																	
0	0	0	14	100%																																																																																																																	
100%	100%	100%	87.5%	96.7%																																																																																																																	
100	0	0	0	100%																																																																																																																	
0	100	0	0	100%																																																																																																																	
0	0	100	5	95.2%																																																																																																																	
0	0	0	95	100%																																																																																																																	
100%	100%	100%	95.0%	98.8%																																																																																																																	
<p>MATRIZ DE CONFUSION DE PRUEBAS</p> <table border="1"> <tr><td>97</td><td>3</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>100</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>0</td><td>100</td><td>0</td></tr> <tr><td>0</td><td>0</td><td>19</td><td>81</td></tr> </table> <p>EFFECTIVIDAD: 94,5%</p>	97	3	0	0	0	100	0	0	0	0	100	0	0	0	19	81	<div style="display: flex; justify-content: space-around;"> <div> <p>Training Confusion Matrix</p> <table border="1"> <tr><td>137</td><td>3</td><td>0</td><td>0</td><td>97.9%</td></tr> <tr><td>4</td><td>131</td><td>0</td><td>0</td><td>97.0%</td></tr> <tr><td>0</td><td>0</td><td>147</td><td>0</td><td>100%</td></tr> <tr><td>0</td><td>2</td><td>0</td><td>136</td><td>98.6%</td></tr> <tr><td>97.2%</td><td>96.3%</td><td>100%</td><td>100%</td><td>98.4%</td></tr> </table> </div> <div> <p>Validation Confusion Matrix</p> <table border="1"> <tr><td>28</td><td>1</td><td>0</td><td>0</td><td>96.6%</td></tr> <tr><td>2</td><td>31</td><td>0</td><td>0</td><td>93.9%</td></tr> <tr><td>0</td><td>0</td><td>24</td><td>0</td><td>100%</td></tr> <tr><td>0</td><td>0</td><td>0</td><td>34</td><td>100%</td></tr> <tr><td>93.3%</td><td>96.9%</td><td>100%</td><td>100%</td><td>97.5%</td></tr> </table> </div> </div> <div style="display: flex; justify-content: space-around; margin-top: 10px;"> <div> <p>Test Confusion Matrix</p> <table border="1"> <tr><td>29</td><td>1</td><td>0</td><td>0</td><td>96.7%</td></tr> <tr><td>0</td><td>31</td><td>0</td><td>0</td><td>100%</td></tr> <tr><td>0</td><td>0</td><td>29</td><td>0</td><td>100%</td></tr> <tr><td>0</td><td>0</td><td>0</td><td>30</td><td>100%</td></tr> <tr><td>100%</td><td>96.9%</td><td>100%</td><td>100%</td><td>99.2%</td></tr> </table> </div> <div> <p>All Confusion Matrix</p> <table border="1"> <tr><td>194</td><td>5</td><td>0</td><td>0</td><td>97.5%</td></tr> <tr><td>6</td><td>193</td><td>0</td><td>0</td><td>97.0%</td></tr> <tr><td>0</td><td>0</td><td>200</td><td>0</td><td>100%</td></tr> <tr><td>0</td><td>2</td><td>0</td><td>200</td><td>99.0%</td></tr> <tr><td>97.0%</td><td>96.5%</td><td>100%</td><td>100%</td><td>98.4%</td></tr> </table> </div> </div>	137	3	0	0	97.9%	4	131	0	0	97.0%	0	0	147	0	100%	0	2	0	136	98.6%	97.2%	96.3%	100%	100%	98.4%	28	1	0	0	96.6%	2	31	0	0	93.9%	0	0	24	0	100%	0	0	0	34	100%	93.3%	96.9%	100%	100%	97.5%	29	1	0	0	96.7%	0	31	0	0	100%	0	0	29	0	100%	0	0	0	30	100%	100%	96.9%	100%	100%	99.2%	194	5	0	0	97.5%	6	193	0	0	97.0%	0	0	200	0	100%	0	2	0	200	99.0%	97.0%	96.5%	100%	100%	98.4%
97	3	0	0																																																																																																																		
0	100	0	0																																																																																																																		
0	0	100	0																																																																																																																		
0	0	19	81																																																																																																																		
137	3	0	0	97.9%																																																																																																																	
4	131	0	0	97.0%																																																																																																																	
0	0	147	0	100%																																																																																																																	
0	2	0	136	98.6%																																																																																																																	
97.2%	96.3%	100%	100%	98.4%																																																																																																																	
28	1	0	0	96.6%																																																																																																																	
2	31	0	0	93.9%																																																																																																																	
0	0	24	0	100%																																																																																																																	
0	0	0	34	100%																																																																																																																	
93.3%	96.9%	100%	100%	97.5%																																																																																																																	
29	1	0	0	96.7%																																																																																																																	
0	31	0	0	100%																																																																																																																	
0	0	29	0	100%																																																																																																																	
0	0	0	30	100%																																																																																																																	
100%	96.9%	100%	100%	99.2%																																																																																																																	
194	5	0	0	97.5%																																																																																																																	
6	193	0	0	97.0%																																																																																																																	
0	0	200	0	100%																																																																																																																	
0	2	0	200	99.0%																																																																																																																	
97.0%	96.5%	100%	100%	98.4%																																																																																																																	

Figura 15: Pruebas comparativas iniciales de desempeño de los clasificadores

Se observó que el método 2 logró clasificar los datos con mayor éxito que el método 1. Se decidió entonces realizar pruebas más exigentes con la red neuronal, reduciendo el número de tramas para construir las distribuciones de prueba. De esta manera, se reduciría también la duración de las señales a analizar.

Es de esperarse que la red neuronal haga una mejor labor en clasificación de los datos, ya que cuenta con más grados de libertad que el método 1, que no utiliza ningún tipo de umbral o ajuste.

## 5.2. Pruebas de desempeño: Red Neuronal

Se realizaron pruebas de clasificación más ajustadas para el método 2, probando con duraciones menores de las señales. Se encontró que a pesar de que la red arroja mejor efectividad que la distancia KL mínima en otros casos, por debajo de los 3,85 segundos cae notablemente el desempeño del clasificador. El número de tramas no permite un entrenamiento de modelo de mezcla de gaussianas que sea efectivo separando las clases, ya que no se logra generar distribuciones de prueba lo suficientemente diferenciadoras entre las clases.

Los resultados de una de las pruebas realizadas a la red neuronal con 3.8 segundos, se encuentran en la Figura 16:



Figura 16: Prueba final de desempeño de la red neuronal

## 6. CONCLUSIONES

Este proyecto propone una metodología para la detección y clasificación del bruxismo nocturno basado en pruebas de laboratorio que buscan replicar dicho comportamiento. A pesar de que bajo ciertas condiciones se logró clasificar los eventos con un alto grado de efectividad, no se puede afirmar que el método sea útil en el estudio de la enfermedad. Es necesario realizar pruebas con señales reales de los patrones que ocurren durante el sueño, ya que pueden ser muy distintas a las obtenidas en el laboratorio y posiblemente no sean estacionarias.

La base de datos del proyecto proviene de una solo sujeto. En futuras investigaciones es importante tomar señales de diferentes personas, ya que el sistema debe ser capaz de generalizar para ser de utilidad.

Los datos pueden presentar problemas por falta de independencia estadística debido a que fueron tomados en un entorno controlado y de manera repetitiva. Las señales reales probablemente no presenten patrones tan bien definidos como los de laboratorio y contengan una aleatoriedad mucho mayor, lo que las haría menos estacionarias.

Debido a las limitaciones en la velocidad del sistema de prototipado utilizado en el sistema de adquisición y almacenamiento, sólo se pudo estudiar 1 de las 3 señales generadas por el acelerómetro a la tasa de muestreo deseada. Es importante poder realizar el análisis de la totalidad de la información proveniente del sensor implementando hardware más apropiado.

En el anteproyecto se propuso utilizar sensores de presión para generar las señales de estudio. Sin embargo, debido a los costos y facilidad de implementación del acelerómetro, se optó por esta alternativa.

Los avances realizados en este trabajo podrían complementar el proyecto realizado en España citado anteriormente (Martínez et al., 2010). El objetivo de aquel grupo de trabajo fue el de lograr una implementación exitosa, y el de esta investigación fue fundamentalmente el análisis de las señales y su clasificación.

Se debe evaluar la ergonomía y bio-compatibilidad del sistema de adquisición y almacenamiento de datos antes de realizar pruebas en un paciente real para medir los riesgos y evitar desencadenar problemas en la salud.

En una próxima etapa, sería importante realizar pruebas de crosvalidación con el fin de determinar la estabilidad de los clasificadores.

En futuras etapas, el análisis de *wavelets* puede utilizarse para hacer la selección de las bandas de frecuencia de interés y los intervalos de análisis.

En este proyecto, la férula instrumentada fue ubicada en el maxilar superior debido a que es la configuración habitual utilizada por los odontólogos por comodidad, y por el espacio que brinda el paladar. Como trabajo futuro, se propone instrumentar una placa de igual manera, pero ubicarla en el

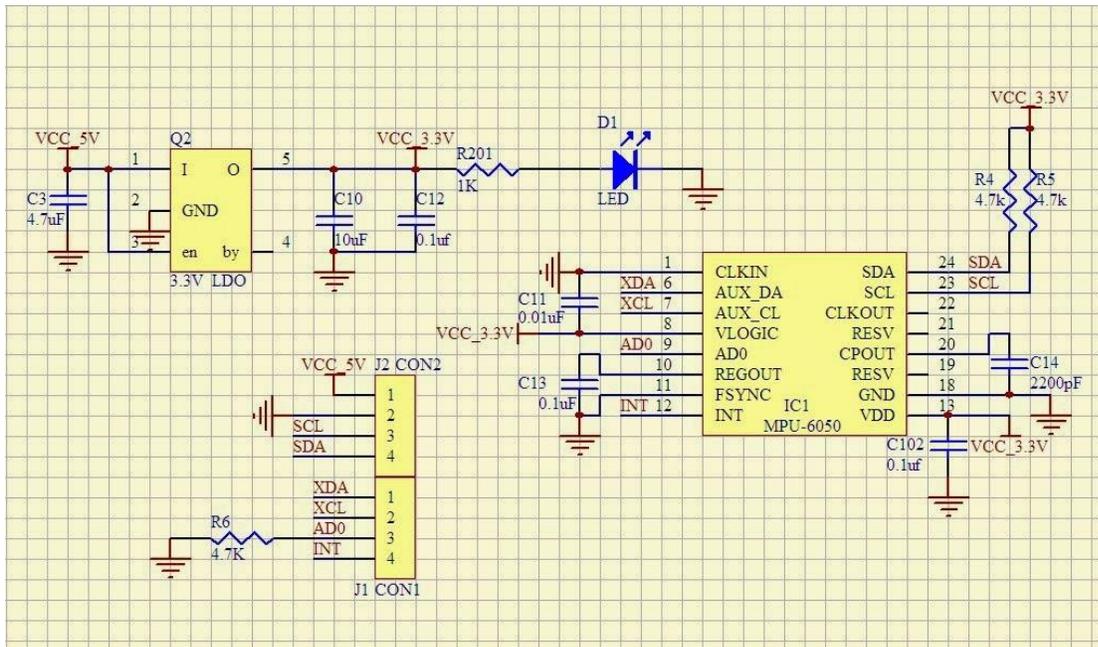
maxilar inferior. A pesar de las limitaciones de espacio, los movimientos fundamentales ocurren realmente en esa ubicación, y probablemente se logre identificar con mayor facilidad los movimientos.

## BIBLIOGRAFÍA

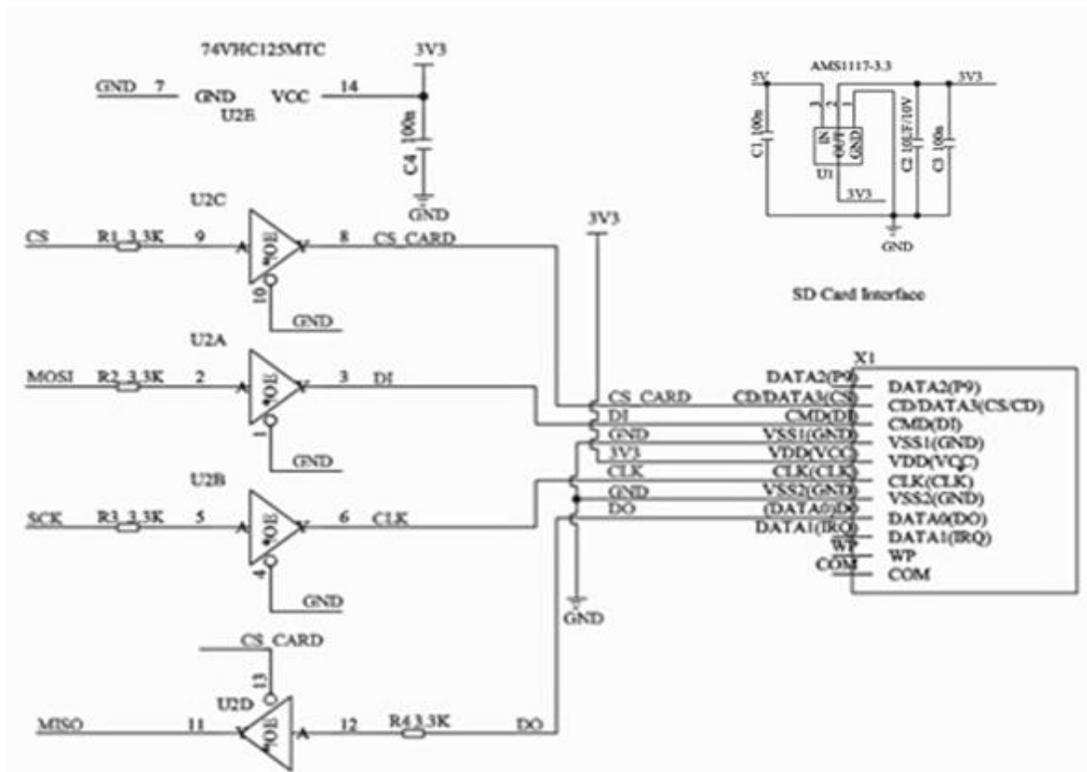
- Castroflorio, T., Deregibus, a., Bargellini, a., Debernardi, C., & Manfredini, D. (2014). Detection of sleep bruxism: Comparison between an electromyographic and electrocardiographic portable holter and polysomnography. *Journal of Oral Rehabilitation*, *41*(5), 163–169.  
<http://doi.org/10.1111/joor.12131>
- Cover, T. M., & Thomas, J. A. (2005). *Elements of Information Theory. Elements of Information Theory*.  
<http://doi.org/10.1002/047174882X>
- Duda, R. O., Hart, P. E., & Stork, D. G. (2000). *Pattern Classification. New York: John Wiley, Section*.  
<http://doi.org/10.1038/npp.2011.9>
- Lavigne, G. J., Huynh, N., Kato, T., Okura, K., Adachi, K., Yao, D., & Sessle, B. (2007). Genesis of sleep bruxism: Motor and autonomic-cardiac interactions. *Archives of Oral Biology*, *52*(4), 381–384.  
<http://doi.org/10.1016/j.archoralbio.2006.11.017>
- Lavigne, G. J., & Montplaisir, J. Y. (1994). Restless legs syndrome and sleep bruxism: prevalence and association among Canadians. *Sleep*, *17*(8), 739–743.
- Martínez, A., Barrientos, A., Díaz, A., Lafont, P., Colorado, J., Castedo, P. L., & González, R. (2010). Polymeric piezoelectric sensors and remote communication for detection of Bruxism. *Proceedings of the IEEE International Conference on Industrial Technology*, 268–273.  
<http://doi.org/10.1109/ICIT.2010.5472691>
- McAuliffe, P. (2012). Types of bruxism. *Journal of the Irish Dental Association*, *58*(July), 138–41.  
Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/22888737>
- McLachlan, G. J., & Basford, K. E. (1988). Mixture Models: Inference and Applications to Clustering. *Statistics Textbooks and Monographs*, *1*, 272. <http://doi.org/10.2307/2348072>
- Melis, M., & Abou-Atme, Y. S. (2003). Prevalence of bruxism awareness in a sardinian population. *Cranio*, *21*, 144–151.
- Oppenheim, A. V., & Schafer, R. W. (2004). From frequency to quefreny: A history of the cepstrum. *IEEE Signal Processing Magazine*, *21*(5). <http://doi.org/10.1109/MSP.2004.1328092>
- Paesani, D. A., Carlsson, G. E., Cifuentes, F., Fuster, S., Galante, J. M., Gianoni, C., & Goldberg, F. (n.d.). *Bruxism : Theory and Practice*.
- Rojas, R. (1996). Neural networks: a systematic introduction. *Neural Networks*, 502.  
[http://doi.org/10.1016/0893-6080\(94\)90051-5](http://doi.org/10.1016/0893-6080(94)90051-5)

## LISTA DE ANEXOS

### Anexo 1. Esquemático del kit acelerómetro GY-521<sup>14</sup>



### Anexo 2. Esquemático del módulo adaptador para memoria micro SD



<sup>14</sup> Fuente: <http://www.hotmcu.com/gy521-mpu6050-3axis-acceleration-gyroscope-6dof-module-p-83.html>