



**CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS
DEL INSTITUTO POLITÉCNICO NACIONAL**

UNIDAD ZACATENCO
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA
SECCIÓN DE BIOELECTRÓNICA

Clasificación de patrones de movimiento de extremidades superiores en registros electroencefalográficos basada en parámetros de Hjorth

Tesis que presenta

Ing. Joaquin Navarro Perales

para obtener el Grado de

Maestro en Ciencias

en la Especialidad de

Ingeniería Eléctrica

Director de la Tesis: Dr. Roberto Muñoz Guerrero

Ciudad de México

Febrero 2017

Agradecimientos

A mi familia: mi padre, mi madre, mis hermanas y mi hermano, por apoyarme siempre para cumplir todas mis metas y ser mi inspiración en todo momento.

Al Dr. Roberto Muñoz Guerrero, por haber creído en mí cuando estuve en el laboratorio 11 por primera vez.

Al Dr. Juan Manuel Gutiérrez Salgado, por las ideas aportadas para el desarrollo de esta tesis y su asesoría en temas de procesamiento avanzado de señales.

A Leo, Martin y Sarai, por su apoyo y amistad y por haber estado siempre conmigo en las buenas y en las malas.

A Adriana, por motivarme y apoyarme siempre y por todo lo que aprendemos y compartimos día a día.

Al resto de mis compañeros de laboratorio: Toño, Esme, Pedro, Luis, Armando, Miguel, Isma, Cosme, Araceli, Bere, Anais, Linda y Chabelita, y a mis compañeros de generación, por el apoyo brindado durante este tiempo y los momentos de convivencia que aligeraban la carga de trabajo.

A Dany, por escucharme y aconsejarme cuando es necesario, ayudarme en todo momento y acompañarme siempre a lo largo de esta etapa.

Al pueblo de México, que a través del pago de sus impuestos hace posible el financiamiento de proyectos como este.

Al Consejo Nacional de Ciencia y Tecnología, por el apoyo otorgado para realizar mis estudios de maestría.

Contenido

Capítulo I. Introducción	1
1.1 Presentación	1
1.2 Planteamiento del problema.....	2
1.3 Objetivos	4
1.3.1 Objetivo general.....	4
1.3.2 Objetivos particulares	4
1.4 Estructura de la tesis.....	5
Capítulo II. Antecedentes.....	6
2.1 Electroencefalografía	6
2.1.1 Bases fisiológicas	7
2.1.2 Ritmos cerebrales	8
2.1.3 Estándar internacional 10-20.....	9
2.2 Parámetros de Hjorth	12
2.3 Máquinas de soporte vectorial	15
2.4 Redes neuronales artificiales	19
2.5 Estado del arte.....	22
Capítulo III. Desarrollo y pruebas	24
3.1 Solución propuesta	24
3.2 Adquisición de datos	25
3.2.1 Criterios de inclusión y exclusión.....	25
3.2.2 Colocación de electrodos	26
3.2.3 Descripción de la prueba	27
3.2.4 Sistema de adquisición.....	30
3.3 Análisis y procesamiento de datos.....	31

3.3.1 Ventaneo	32
3.3.2 Extracción de características	33
3.3.3 Normalización	33
3.3.4 Clasificación.....	37
3.3.4.1 Máquinas de soporte vectorial	38
3.3.4.2 Redes neuronales artificiales	39
3.4 Validación.....	40
3.4.1 Validación cruzada	40
3.4.2 Repetición de la prueba	41
3.4.3 ANOVA	42
3.4.4 Comparación de los parámetros de Hjorth con la dimensión fractal	43
Capítulo IV. Resultados y discusión.....	45
4.1 Porcentajes de clasificación	45
4.2 Sensitividad, especificidad y exactitud	49
4.3 Repetición de la prueba	52
4.4 Comparación con la literatura	54
4.5 Comparación con el uso de la dimensión fractal.....	55
Capítulo V. Conclusiones y perspectivas	58
Apéndice A. Características de la tarjeta ADS1299-EEG	62
Referencias	63

Índice de figuras

Fig. 2.1. Primer EEG registrado por Hans Berger en 1924	6
Fig. 2.2. Neurona piramidal.	7
Fig. 2.3. Áreas funcionales de la corteza cerebral.....	9
Fig. 2.4. Medida en el plano sagital.....	10
Fig. 2.5. Medida en el plano coronal.	10
Fig. 2.6. Medida en el plano horizontal.....	11
Fig. 2.7. Configuración final del Sistema Internacional 10-20.....	12
Fig. 2.8. Representación gráfica de una SVM.	16
Fig. 2.9. Efecto del valor de γ en la frontera de decisión.....	17
Fig. 2.10. Efecto de C en la frontera de decisión.....	18
Fig. 2.11. Comparación entre elementos de neuronas biológicas y artificiales.	20
Fig. 2.12. Perceptrón multicapa con dos capas ocultas	21
Fig. 3.1. Diagrama general de la solución propuesta	25
Fig. 3.2. Posiciones de los electrodos utilizados	26
Fig. 3.3. Gorra con electrodos de Ag-AgCl de Electro-Cap ®	27
Fig. 3.4. Modelo virtual utilizado.	28
Fig. 3.5. Diagrama de distribución de tiempos por repetición.....	29
Fig. 3.6. Tarjeta ADS1299EEG-FE de Texas Instruments ®.....	31
Fig. 3.7. Ventana Hamming.....	33
Fig. 3.8. Gráfica de los tres primeros componentes principales sin normalizar los datos	35

Fig. 3.9. Gráfica de los tres primeros componentes principales estandarizando los datos	35
Fig. 3.10. Gráfica de los tres primeros componentes principales centrando los datos por medio del centroide	36
Fig. 3.11. Resultados de la búsqueda de cuadrícula para un sujeto de prueba	38
Fig. 3.12. K-fold con $k = 4$	41
Fig. 4.1. Comparación entre porcentajes de clasificación	47
Fig. 4.2. Sensitividad, especificidad y exactitud para flexión - extensión de hombros.	50
Fig. 4.3. Sensitividad, especificidad y exactitud para pronación – supinación de muñecas.....	51
Fig. 4.4. Comparación entre parámetros de Hjorth y FD	57

Índice de tablas

Tabla. 3.1. Porcentajes de clasificación de movimientos de flexión-extensión de hombros con distintos esquemas de normalización	37
Tabla. 3.2. Arquitecturas de red optimizadas para clasificar movimientos de flexión-extensión de hombros.	40
Tabla. 4.1. Porcentajes de clasificación para flexión-extensión de hombros	45
Tabla. 4.2. Porcentajes de clasificación para pronación-supinación de muñecas.	46
Tabla 4.3. Resultados de los movimientos de flexión-extensión de hombros al repetir la prueba a cuatro de los sujetos de la base de datos	52
Tabla 4.4. Resultados de los movimientos de flexión-extensión de hombros al repetir la prueba a cuatro de los sujetos de la base de datos.	53
Tabla 4.5. Porcentajes de clasificación obtenidos utilizando dimensión fractal como característica.	56

Lista de abreviaturas

ANN	Red neuronal artificial
ANOVA	Análisis de la varianza
AVA	Todos contra todos
BCI	Interfaz cerebro computadora
ECoG	Electrocorticografía
EEG	Electroencefalografía
EMG	Electromiografía
FD	Dimensión fractal
FFT	Transformada rápida de Fourier
fMRI	Resonancia magnética funcional
KNN	K-ésimo vecino más cercano
LDA	Análisis discriminante lineal
LVQ	Aprendizaje de cuantificación vectorial
MEG	Magnetoencefalografía
MLP	Perceptrón multicapa
OVA	Uno contra todos
PARAFAC	Análisis de factores paralelos
PCA	Análisis de componentes principales
PGA	Amplificador de ganancia programable
PNN	Red neuronal probabilística
RMS	Valor cuadrático medio
SVM	Máquina de soporte vectorial
WPT	Transformada wavelet packet
WT	Transformada wavelet

Resumen

En el presente trabajo se evaluó el desempeño de los parámetros de Hjorth para caracterización de movimientos de extremidades superiores a partir del registro electroencefalográfico (EEG). Dichos parámetros son tres indicadores estadísticos que se calculan en el dominio del tiempo y revelan información del dominio de la frecuencia al relacionarse con ciertos momentos espectrales. Estos parámetros fueron comparados con la dimensión fractal, que implica las mismas ventajas y ha reportado mejores resultados en aplicaciones similares.

Se generó una base de datos de EEG registrados durante la ejecución de los siguientes movimientos: flexión - extensión de hombro y pronación - supinación de muñeca de cada extremidad. La base de datos se compone de diez sujetos de prueba. Los registros fueron realizados con los ojos abiertos y cerrados.

Como clasificadores se utilizaron máquinas de soporte vectorial (SVM, *Support Vector Machines*) y redes neuronales artificiales (ANN, *Artificial Neural Networks*). Se realizaron pruebas separadas con cada par de movimientos, utilizando cuatro clases simultáneamente, con los movimientos agonista y antagonista de cada extremidad.

Con la metodología propuesta es posible obtener porcentajes de clasificación mayores al 90%. Los resultados obtenidos indican que los parámetros de Hjorth son una herramienta adecuada para la identificación de movimientos de extremidades superiores.

Abstract

In this work, the performance of Hjorth's parameters was evaluated for characterization of movements of the upper limbs based in the electroencephalographic (EEG) recording. These parameters are three statistic indicators that are calculated in the time domain and reveal information in the frequency domain for being related with certain spectral moments. These parameters were compared with the fractal dimension, which have the same advantages and have been reported best results in similar applications.

A database of EEG registered during execution of movements was generated. The movements selected are: flexion - extension of shoulder and pronation - supination of wrist of each limb. The database is composed of ten test subjects and the registers were performed with eyes open and closed.

Support Vector Machines (SVM) and Artificial Neural Networks (ANN) were used as classifiers. Separated tests were performed, using four classes at a time, with the agonist and antagonist movements of each limb.

With the proposed method it is possible to obtain classification percentages higher than 90%. The obtained results indicate that Hjorth's parameters are a suitable tool for identification of upper limb movements.

Introducción

1.1. Presentación

La interacción con un entorno físico o virtual por medio de la interpretación detallada de la actividad cerebral representa un gran reto para nuestra época y es un punto de convergencia de múltiples áreas como las ciencias computacionales, la neurociencia y la ingeniería.

Las aplicaciones que se esperan dentro de este campo son variadas, desde el control de dispositivos encargados de reintegrar funciones motoras como sillas de ruedas, prótesis y exoesqueletos, herramientas orientadas a la comunicación, auxiliares en rehabilitación neuronal e incluso innovaciones en la industria de los videojuegos, por medio de realidad virtual y aumentada.

Existen distintas técnicas de registro de la actividad cerebral, entre las que tenemos: electroencefalografía (EEG), magnetoencefalografía (MEG), electrocorticografía (ECoG) y resonancia magnética funcional (fMRI). Esas técnicas poseen ventajas y desventajas en cuanto a su portabilidad, invasividad, coste y resoluciones temporal y espacial [1, 2].

Para desarrollar alguna de las aplicaciones antes descritas, además de seleccionar una técnica de registro de la actividad cerebral se debe contar con las herramientas necesarias para extraer la información útil para nuestros fines, a fin de realizar un análisis adecuado de esos datos que permita modelar esa información.

1.2. Planteamiento del problema

Existen distintas enfermedades que afectan las funciones motoras de quienes las padecen, alterando gravemente su calidad de vida. Como solución a estas limitaciones han surgido las interfaces cerebro computadora (BCI, *Brain Computer Interface*), sistemas orientados a permitir la interacción con un entorno físico o virtual por medio del registro y procesamiento de la actividad cerebral [3].

La señal más utilizada para el desarrollo de BCI es la EEG debido a que su registro es no invasivo, portable y de bajo costo, mientras que la invasividad de la ECoG es una gran desventaja y tanto la MEG como la fMRI implican el uso de equipos costosos y de gran tamaño. Sin embargo, aun cuando la EEG presenta una resolución temporal aceptable, tiene la desventaja de poseer una resolución espacial limitada, por lo que se debe hacer una selección estratégica de las posiciones de los electrodos utilizados. Otra desventaja se debe a que las señales son registradas desde el cuero cabelludo y existen varias capas de tejido conectivo que cubren al encéfalo, por lo tanto las señales son de amplitud muy baja, en el orden de microvolts, y son muy susceptibles a la presencia de ruido y artefactos. Además, dichas señales incluyen información de una gran variedad de tareas además de la actividad motora.

Por estas razones, es muy importante utilizar las características de las señales que resalten de mejor manera las variaciones de nuestro fenómeno de interés. Para ello disponemos de una gran variedad de técnicas matemáticas que pueden calcularse en el dominio del tiempo, de la frecuencia o poseer información de ambos dominios. Las técnicas del dominio del tiempo generalmente son de bajo costo computacional pero es necesaria la combinación de muchas de ellas porque suelen aportar información muy general de los fenómenos de interés [4]. Las técnicas en el dominio de la frecuencia y representaciones tiempo-frecuencia son capaces de aportar información específica de los fenómenos de interés pero se basan en transformaciones complejas que requieren una gran cantidad de operaciones

matemáticas [5]. Aunque esto no representa un problema para los dispositivos disponibles hoy en día, entre menor sea el costo computacional que impliquen dichas herramientas, la respuesta del sistema será más adecuada.

En el presente trabajo se propone la evaluación de los parámetros de Hjorth como características para la identificación de patrones motores en el EEG. Dichos parámetros son tres indicadores estadísticos calculados en el dominio del tiempo que revelan información general en el dominio de la frecuencia al relacionarse con algunos momentos espectrales [6]. Para comparar el desempeño de los parámetros de Hjorth, se realizaron pruebas con la dimensión fractal (FD, *Fractal Dimension*) como característica, debido a que ambos se calculan en el dominio del tiempo, revelan información general del dominio de la frecuencia [7] y se han comparado anteriormente en trabajos orientados a BCI, obteniendo mejores resultados con la FD [8, 9].

En los trabajos donde se clasifican movimientos de articulación de hombro y muñeca identificando más de dos clases [5, 10-12], el número máximo de clases simultáneas es cinco y ninguno de ellos utilizó los parámetros de Hjorth, por lo tanto se decidió abordar de manera separada los movimientos de flexión-extensión de hombros y pronación-supinación de muñecas, identificando cuatro clases a la vez con cada movimiento y su antagonista por cada extremidad, esto para evitar adjudicar un bajo desempeño a los parámetros de Hjorth debido al empleo de un mayor número de clases simultáneas que el reportado.

1.3. Objetivos

1.3.1. Objetivo general

Evaluar el desempeño de los parámetros de Hjorth como indicadores de actividad motora por medio de la actividad eléctrica cerebral generada durante la ejecución de movimientos de extremidades superiores. Los modelos resultantes deberán ser capaces de adaptarse a distintos sujetos de prueba manteniendo fijas sus propiedades principales.

1.3.2. Objetivos particulares

- Establecer un protocolo de adquisición de señales EEG registradas durante la flexión - extensión de hombro, y pronación - supinación de muñeca, vinculando un modelo virtual que permite indicar los movimientos a ejecutar con el programa encargado del registro del EEG.
- Generar una base de datos de registros EEG de 10 sujetos de prueba, realizados durante la ejecución de movimientos de extremidades superiores con los ojos abiertos y cerrados.
- Llevar a cabo un análisis de los datos que permita identificar si existe alguna técnica de normalización favorable para los parámetros de Hjorth y si es necesario el uso de los tres.
- Obtener modelos basados en SVM y ANN capaces de identificar cuatro clases a la vez utilizando los movimientos agonista y antagonista de cada extremidad.

- Realizar una comparación entre ambos clasificadores, entre los resultados de los registros con ojos abiertos y cerrados y entre los resultados obtenidos a través de los parámetros de Hjorth y la dimensión fractal.

1.4. Estructura de la tesis

La presente tesis se encuentra dividida en cinco capítulos. En el primero se expusieron los problemas existentes respecto a la clasificación de movimientos con EEG y se estableció el alcance de este trabajo. En el segundo se describen los conceptos más relevantes para el desarrollo de este trabajo y se hace una revisión de la literatura. En el tercero se describe la metodología propuesta. En el cuarto se exponen y analizan los resultados obtenidos y en el quinto se exponen las conclusiones de este proyecto y el posible trabajo futuro.

Antecedentes

El fin de este capítulo es otorgar un panorama general sobre la electroencefalografía como método de registro de la actividad cerebral y los parámetros de Hjorth como características útiles para el reconocimiento de patrones. Además se exponen los fundamentos teóricos de los clasificadores evaluados. Por último, se realiza una revisión de los trabajos encontrados en la literatura que guardan relación con este proyecto.

2.1. Electroencefalografía

Es una técnica de evaluación neurofisiológica que registra la actividad eléctrica cerebral de manera no invasiva por medio de electrodos fijados en distintas posiciones del cuero cabelludo.

El primer electroencefalograma fue registrado en 1924 por el psiquiatra alemán Hans Berger, continuando el trabajo realizado por Richard Caton, un cirujano británico que había podido registrar la actividad eléctrica de hemisferios cerebrales expuestos pertenecientes a monos y conejos en 1875 [13]. Después de cinco años de analizar sus datos, Berger reportó la existencia de los ritmos alfa y beta [14].




Fig. 2.1. Primer EEG registrado por Hans Berger en 1924, en la parte inferior aparece una onda senoidal de 10 Hz.

2.1.1. Bases fisiológicas

La principal fuente de actividad eléctrica que es registrada en el electroencefalograma proviene de las neuronas piramidales. Estas neuronas poseen un cuerpo celular triangular, un único axón, múltiples dendritas basales y una gran ramificación dendrítica apical (Fig. 2.2). Estas neuronas están orientadas verticalmente, con sus dendritas apicales paralelas unas a otras, lo cual hace que una cantidad considerable de corriente pueda fluir en la misma dirección, cuyo sentido depende de si la sinapsis es excitatoria o inhibitoria. En cambio, las neuronas no piramidales no contribuyen de manera importante al registro, debido a que sus dendritas se orientan en todas direcciones [15].

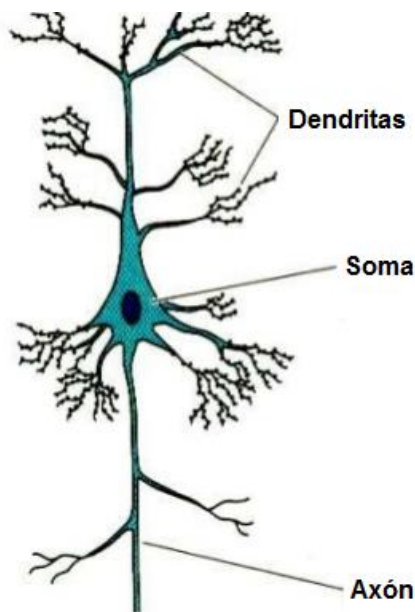


Fig. 2.2. Neurona piramidal.

Para poder registrar los potenciales cerebrales desde el cuero cabelludo es necesario que miles o incluso millones de neuronas disparen sincrónicamente, sólo de esta manera se puede sumar una cantidad suficiente de potenciales para que puedan ser registrados después de atravesar todo el cráneo. Por esta razón, la

amplitud de las ondas cerebrales está determinada por el número de neuronas que disparen en sincronía, no por el nivel de actividad eléctrica total [16].

2.1.2. Ritmos cerebrales

Los registros EEG poseen bandas de frecuencia específicas que se relacionan con ciertos estados mentales [17]:

- Delta (δ): 0.5-4 Hz. Se asocia con el sueño profundo. Cuando su actividad es excesiva indica encefalopatías.
- Theta (θ): 4-7 Hz. Se presentan principalmente en niños. Son indicadores de estrés y frustración en adultos.
- Alfa (α): 8-13 Hz. Asociada con la relajación. Se atenúa con los ojos abiertos. Se localizan principalmente en el lóbulo occipital, sobre la corteza visual (Fig. 2.3).
- Mu (μ): 8-13 Hz. Variante de las ondas alfa. Disminuye durante el movimiento o su planeación. Se registran sobre la corteza sensoriomotora, localizada en la parte posterior del lóbulo frontal (Fig. 2.3).
- Beta (β): 13-30 Hz. Se relaciona con el pensamiento activo y resolución de problemas. Prevalece en los lóbulos frontal y parietal.
- Gamma (γ): Más de 30 Hz. Se relaciona con el procesamiento de información.

Durante la planeación y ejecución de movimientos de extremidades superiores tiene lugar una disminución de la energía de las bandas μ y β , seguida de un incremento al finalizar su ejecución [18]. Por esta razón son las bandas más

utilizadas para identificación de movimientos. Sin embargo, existe evidencia de cambios en las bandas θ y γ durante tareas similares [19].




Fig. 2.3. Áreas funcionales de la corteza cerebral.

2.1.3. Estándar internacional 10-20

Es un patrón para la localización de los electrodos utilizados en EEG. Fue propuesto por Herbert H. Jasper en 1947 [20]. Recibe ese nombre debido a que las posiciones de los electrodos se obtienen a partir de tres medidas del cráneo, que son divididas en intervalos de 10% y 20%.

La primera medida tiene lugar en el plano medio sagital iniciando en el nasión y terminando en el inión y es dividida por medio de cinco marcas que se colocan en los siguientes puntos: la primera se coloca al 10% de la longitud total a partir del nasión y se identifica como Fp (frontopolar), las cuatro siguientes se localizan cada 20% de la longitud total sobre esa misma línea y se etiquetan de la siguiente manera: F (frontal), P (parietal), C (central) y O (occipital) (Fig. 2.4).




Fig. 2.4. Medida en el plano sagital.

La segunda medida se realiza en un plano coronal, entre los dos puntos preauriculares, pasando por la marca etiquetada como C. Partiendo de cada punto preauricular se coloca una marca correspondiente al 10% de esta distancia, estas marcas son etiquetadas como T (temporal). Partiendo de estos puntos se colocan otras dos marcas en dirección a C, al 20% de la distancia total, estas posiciones serán denominadas C laterales (Fig. 2.5).




Fig. 2.5. Medida en el plano coronal.

La tercera medida corresponde a un plano horizontal ligeramente oblicuo y se extiende sobre el área temporal, pasando por Fp y O. Dos marcas son colocadas a los lados de Fp, cada 10% del total, y se denominan Fp izquierdo y Fp derecho. Del mismo modo se colocan pares de marcas cada 20% y son nombradas: frontales inferiores, temporales medios, temporales posteriores y occipitales (Fig. 2.6).




Fig. 2.6. Medida en el plano horizontal.

Para indicar las posiciones restantes se realizan dos medidas adicionales, desde los electrodos frontopolares hasta los occipitales, pasando por C izquierdo y C derecho. Se colocan marcas cada 25% y se nombran F laterales y P laterales.

De esta manera se definen 19 posiciones de electrodos, utilizando números impares para las posiciones localizadas en el hemisferio izquierdo: Fp1, F3, F7, C3, T3, P3, T5 y O1 y números pares para el hemisferio derecho: Fp2, F4, F8, C4, T4, P4, T6 y O2. A las marcas F, C y P se les agrega una "z" para definir los electrodos

centrales: Fz, Cz y Pz y se colocan dos electrodos en los lóbulos auriculares, A1 y A2 (Fig. 2.7).




Fig. 2.7. Configuración final del Sistema Internacional 10-20.

2.2. Parámetros de Hjorth

Son tres indicadores estadísticos utilizados en procesamiento de señales que son calculados en el dominio del tiempo y revelan información general del dominio de la frecuencia. Los parámetros se denominan: actividad, movilidad y complejidad. También son conocidos como descriptores normalizados de pendiente, debido a que describen cuantitativamente al EEG en términos de amplitud, pendiente y dispersión de la pendiente.

Los parámetros de Hjorth fueron propuestos en 1970 por Bo Hjorth, siendo su primera aplicación el análisis de las variaciones de dichos parámetros durante el sueño y su relación con la actividad metabólica [6].

Los parámetros de Hjorth se describen matemáticamente de la siguiente manera:

$$Actividad = var(y(t)) \quad (1)$$

$$Movilidad = \sqrt{\frac{var(y'(t))}{var(y(t))}} \quad (2)$$

$$Complejidad = \sqrt{\frac{movilidad(y'(t))}{movilidad(y(t))}} \quad (3)$$

La actividad mide la varianza de la amplitud de la señal. En el dominio de la frecuencia se relaciona con la superficie de su espectro de potencia y por lo tanto con su potencia media.

La movilidad representa la proporción entre la desviación estándar de la pendiente de la señal y la desviación estándar de su amplitud. Es proporcional a la desviación estándar del espectro de potencia de la señal y se relaciona con la frecuencia media.

La complejidad es una medida de similitud de la forma de una señal senoidal. Cualquier desviación de esa forma se cuantifica como un incremento de la unidad. La complejidad aporta información general sobre el ancho de banda de la señal.

Para entender la manera en que los parámetros de Hjorth se pueden relacionar con ciertas características del dominio de la frecuencia, debemos partir del concepto de momento espectral, que es una cantidad derivada del espectro de potencia de acuerdo a la siguiente fórmula:

$$m_n = \int_{-\infty}^{\infty} \omega^n S(\omega) d\omega \quad (4)$$

Donde m_n es el momento de orden n y $S(\omega)$ es el espectro de potencia.

Empleando el teorema de Parseval, podemos utilizar el momento espectral de orden cero para realizar la siguiente equivalencia entre dominios:

$$m_0 = \int_{-\infty}^{\infty} S(\omega) d\omega = \frac{1}{T} \int_{t-T}^t f^2(t) dt \quad (5)$$

Para una señal con media cero, la ecuación (5) hace referencia a su varianza, por lo que se demuestra la equivalencia entre el momento espectral de orden cero y el primer parámetro de Hjorth.

Se pueden formular equivalencias similares para los momentos de segundo y cuarto orden:

$$m_2 = \int_{-\infty}^{\infty} \omega^2 S(\omega) d\omega = \frac{1}{T} \int_{t-T}^t \left(\frac{df}{dt}\right)^2 dt \quad (6)$$

$$m_4 = \int_{-\infty}^{\infty} \omega^4 S(\omega) d\omega = \frac{1}{T} \int_{t-T}^t \left(\frac{d^2f}{dt^2}\right)^2 dt \quad (7)$$

Esto hace posible una representación de los parámetros de Hjorth mediante momentos espectrales:

$$\text{Actividad} = m_0 \quad (8)$$

$$\text{Movilidad} = \sqrt{\frac{m_2}{m_0}} \quad (9)$$

$$Complejidad = \sqrt{\frac{m_4/m_2}{m_2/m_0}} = \sqrt{\frac{m_4 m_0}{m_2^2}} \quad (10)$$

2.3. Máquinas de soporte vectorial

Las máquinas de soporte vectorial (SVM, *Support Vector Machines*) son algoritmos de aprendizaje supervisado que fueron propuestos en 1992 por Boser, Guyon y Vapnik [21].

Por definición son clasificadores binarios lineales, por lo que se basan en una función discriminante lineal de la siguiente forma:

$$f(x) = w^T x + b \quad (11)$$

Donde w es el vector de pesos y b se conoce como *bias*. Cuando $b = 0$, los puntos que cumplen $w^T x = 0$ son todos los puntos perpendiculares a w , una línea en dos dimensiones, un plano en tres dimensiones y de manera general, un hiperplano [22]. Cuando $b \neq 0$ el hiperplano pasa por el origen y conforme cambia se aleja de él.

De esta manera, el hiperplano divide al espacio en dos regiones. La pertenencia de cada punto a una región dependerá del signo del resultado de la ecuación (11). Debido a esto el hiperplano también se conoce como frontera de decisión y los puntos más cercanos a ella se conocen como vectores de soporte. La distancia entre los vectores de soporte y la frontera de decisión se conoce como margen (Fig. 2.8).

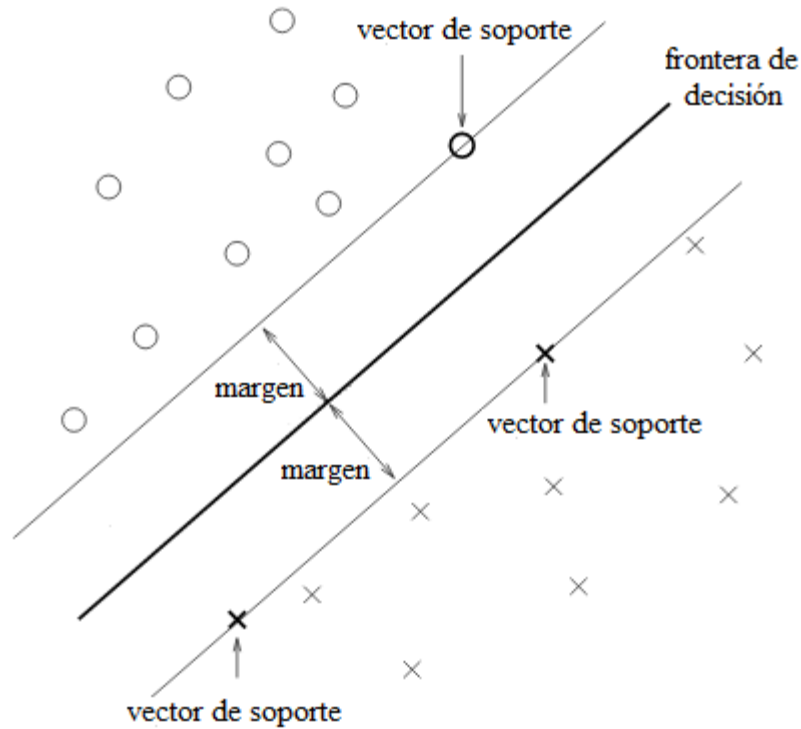


Fig. 2.8. Representación gráfica de una SVM.

Aunque por definición las SVM poseen fronteras de decisión lineales, es posible emplear fronteras de decisión no lineales transformando nuestros datos a un nuevo espacio por medio de una función no lineal ϕ . La función discriminante se define de la siguiente manera:

$$f(x) = w^T \phi(x) + b \quad (12)$$

Sin embargo, el mapeo explícito hacia un nuevo espacio de características no es óptimo en términos de costo computacional, tomando en cuenta que los datos pueden ser de dimensionalidad alta. Las funciones kernel solucionan este problema haciendo el mapeo de manera implícita por medio del uso de productos punto únicamente. Estas funciones se definen de la siguiente manera:

$$k(x, x') = \phi(x)^T \phi(x') \quad (13)$$

Donde x' es un vector de entrada que no está etiquetado y se desea conocer de qué lado de la frontera de decisión se encuentra.

Una función kernel muy utilizada es la función radial base, que es definida por la siguiente ecuación:

$$k(x, x') = e^{-(\gamma \|x-x'\|^2)} \quad (14)$$

Donde γ es la anchura de la campana de Gauss, conforme aumenta, la frontera de decisión adquiere una mayor flexibilidad (Fig. 2.9).

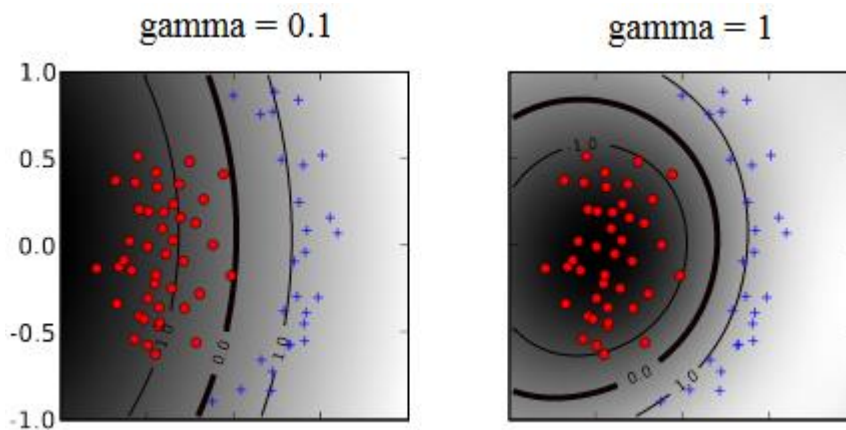


Fig. 2.9. Efecto del valor de γ en la frontera de decisión.

Al llevar a cabo una tarea de clasificación con SVM el objetivo es maximizar los márgenes, pues entre más grandes sean se incrementa la capacidad de generalización, es decir, la capacidad de funcionar adecuadamente en casos nuevos. Para ello existe un parámetro llamado constante de margen suave (C) que ayuda a maximizar el margen al permitir la clasificación errónea de algunos puntos (Fig. 2.10). Tanto C como los parámetros propios de cada kernel se denominan hiperparámetros.




Fig. 2.10. Efecto de C en la frontera de decisión.

Del mismo modo en que es posible el uso de fronteras de decisión no lineales con SVM, es posible su aplicación para problemas donde intervienen más de dos clases. Esto se puede llevar a cabo tanto a través de esquemas que utilizan múltiples clasificadores binarios como de algoritmos más complejos que se enfocan en resolver un único problema de optimización, encontrando múltiples hiperplanos simultáneamente. Existe evidencia de que ambos tipos de esquemas podrían tener rendimiento similar siempre y cuando se realice una adecuada selección de hiperparámetros [23].

Los esquemas básicos con múltiples clasificadores binarios son llamados: uno contra todos (OVA, *one-vs-all*) y todos contra todos (AVA, *all-vs-all*). Siendo N el número de clases, OVA implica utilizar N diferentes clasificadores, cada uno enfocado en distinguir una clase de entre todas las demás y al final se decide cuál fue el resultado más adecuado. AVA, en cambio, utiliza $\binom{N}{2}$ clasificadores, cada uno encargado de separar un par de clases [23].

2.4. Redes neuronales artificiales

Las redes neuronales artificiales (ANN, *Artificial Neural Networks*) son conjuntos de procesadores interconectados que transportan información realizando operaciones matemáticas. Cada procesador es un modelo computacional de una neurona biológica y consiste en una red de conexiones de entrada, una función de propagación que pondera y combina las entradas, una función de activación que evalúa el resultado de la función de propagación y una salida.

Los procesadores mencionados se conocen como neuronas artificiales, fueron propuestos originalmente por McCulloch y Pitts [24] y su comportamiento se expresa matemáticamente de acuerdo a la siguiente ecuación:

$$y(t) = f\left(\sum_{i=1}^N w_i x_i(t) + \theta\right) \quad (15)$$

Donde N es el número de entradas x_i , la sumatoria es la función de propagación, a los valores w_i se les conoce como pesos, f es la función de activación, θ es un valor conocido como *bias* que funciona como umbral para trasladar la ordenada al origen de la función de activación y $y(t)$ es la salida (Fig. 2.11).

Existen muchas formas de realizar la interconexión de procesadores, generando distintos tipos de arquitecturas de red. Una de las arquitecturas más utilizadas es el perceptrón multicapa, donde cada capa es un conjunto de neuronas colocadas en paralelo y cada neurona se conecta únicamente con las neuronas de la capa siguiente, realizando propagación hacia adelante (*feedforward*), esto quiere decir que la información únicamente se dirige de la entrada hacia la salida.

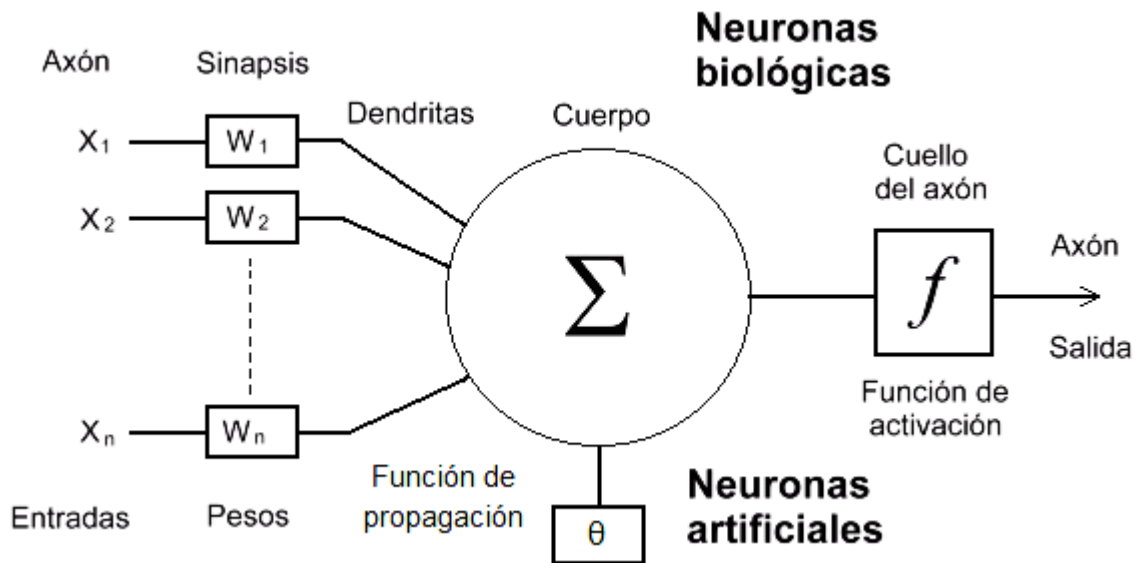


Fig. 2.11. Comparación entre elementos de neuronas biológicas y artificiales.

Un perceptrón multicapa (MLP, *Multilayer Perceptron*) consiste en una capa de entrada encargada de distribuir los datos, al menos una capa oculta, y una capa de salida (Fig. 2.12). Las neuronas de cada capa tienen la misma función de activación.

Se conoce como aprendizaje al proceso de modificar los pesos y valores de *bias* en una red de acuerdo a ciertas entradas con la finalidad de obtener un modelo que generalice su respuesta a entradas nuevas. Esto se lleva a cabo de acuerdo a un algoritmo de aprendizaje específico.

El algoritmo más utilizado para el perceptrón multicapa se llama retropropagación del error (*backpropagation*) y consiste en los siguientes pasos:

1. Inicializar los pesos en valores pequeños.
2. Elegir aleatoriamente una entrada x_i y propagar esa entrada a través de todas las capas.
3. Comparar la salida obtenida con la salida esperada calculando un error.
4. Con base en el error calculado se ajustan los pesos de la última capa.

5. Se propaga el error a la capa anterior para realizar el mismo ajuste, hasta llegar a la capa de entrada.
6. Repetir este proceso hasta que el error sea menor a un umbral predefinido.




Fig. 2.12. Perceptrón multicapa con dos capas ocultas.

Para evaluar adecuadamente el desempeño de una red es necesario dividir el total de entradas disponibles en conjuntos de entrenamiento y prueba. Con el conjunto de entrenamiento se realiza el ajuste de pesos y *bias* de acuerdo al algoritmo de aprendizaje y una vez finalizado este proceso se utiliza el conjunto de prueba para determinar qué tanta capacidad de generalización posee el modelo resultante.

El error calculado se conoce como función de costo. Es necesario que el umbral de la función de costo no sea tan bajo como para que el modelo resultante responda únicamente al conjunto de entrenamiento. Una cantidad utilizada para este fin es el error cuadrático medio.

2. 5. Estado del arte

El único trabajo directamente relacionado con el uso de los parámetros de Hjorth para la identificación de movimientos en EEG registrados durante su ejecución es el desarrollado por Schlögl *et al* en 1996 [25]. El objetivo de ese estudio fue diferenciar el movimiento de los dos dedos índices de tres sujetos de prueba, utilizando análisis discriminante lineal (LDA, *Linear Discriminant Analysis*) y aprendizaje de cuantificación vectorial (LVQ, *Learning Vector Quantization*) como clasificadores, obteniendo porcentajes de clasificación entre sujetos de $83.75 \pm 5.79\%$ y $81.83 \pm 7.50\%$ respectivamente.

En 2013, Shedeed *et al* [12] llevaron a cabo la clasificación de tres movimientos: abducción y aducción de hombro y cierre de puño. Se compararon tres técnicas de extracción de características: transformada rápida de Fourier (FFT, *Fast Fourier Transform*), WT y análisis de componentes principales (PCA, *Principal Components Analysis*), en los tres casos se utilizó un MLP como clasificador. Se utilizó un solo sujeto de prueba con registros realizados con ojos abiertos y se obtuvieron los siguientes porcentajes de clasificación: 86.7% con FFT, 91.1% con WT y 85.6% con PCA.

Dos años más tarde, Hossain *et al* [4] realizaron la clasificación del movimiento de ambas manos, (no se especificó cuáles movimientos) utilizando un conjunto de características del dominio del tiempo en el EEG (energía, varianza escalada, valor RMS, *roll off*, entropía aproximada, cruces por cero y valor medio absoluto) extraídas después de utilizar la transformada wavelet (WT, *Wavelet Transform*), y una red neuronal probabilística (PNN, *Probabilistic Neural Network*) como clasificador. Se utilizaron registros de un solo sujeto que mantuvo los ojos cerrados durante la prueba y se obtuvo un porcentaje de clasificación de 99.1%.

Tomando como punto de partida el trabajo anterior, en 2015 Bashar *et al* [5], clasificaron cuatro movimientos: flexión y extensión de hombro en ambas extremidades. La extracción de características fue realizada partiendo de la Transformada Wavelet Packet (WPT, *Wavelet Packet Transform*), posteriormente se aplicó la FFT a los coeficientes de detalle y al final se calculó la curtosis de la magnitud de los coeficientes de Fourier. Como clasificador se utilizó el K-Vecino Más Cercano (KNN, K-Nearest Neighbor). La prueba se llevó a cabo con un solo sujeto con ojos cerrados y el porcentaje de clasificación obtenido fue de 92.84%.

Los trabajos enfocados en clasificar movimientos de las articulaciones de la muñeca y del hombro enfocados a más de dos clases reportan la identificación simultánea de tres clases [12], cuatro clases [5, 10] y hasta cinco clases [11]. Además existen variaciones en cuanto a si los sujetos mantienen sus ojos abiertos o cerrados durante la prueba y en la mayoría de ellos se utilizó un solo sujeto, lo cual no garantiza robustez en su metodología.

Los trabajos que no utilizaron los parámetros de Hjorth se basaron en la WT de alguna forma, ya que en un caso fue la herramienta que otorgó mejores resultados y en los dos restantes incluso se combinó con distintas características del dominio del tiempo o de la frecuencia. Esto implica un mayor costo computacional.

Desarrollo y pruebas

En el presente capítulo se describe la metodología propuesta para cumplir con los objetivos de este trabajo, abordando los siguientes puntos: las características del protocolo de adquisición de señales, los pasos que conforman el análisis y procesamiento de datos y las pruebas necesarias para llevar a cabo la validación de los modelos obtenidos.

3.1. Solución propuesta.

La solución propuesta se muestra de manera general en la Fig. 3.1 y se puede dividir en los siguientes puntos:

- *Adquisición de datos.* Comprende el sistema utilizado para generar la base de datos, las posiciones de los electrodos utilizados y los movimientos realizados durante la prueba.
- *Análisis y procesamiento de datos.* Se divide en las siguientes etapas: ventaneo, extracción de características, normalización y clasificación. Se describen los criterios y técnicas utilizados para seleccionar las condiciones de cada etapa.
- *Validación.* Incluye las pruebas utilizadas para garantizar repetibilidad y robustez en los modelos resultantes. Así como el análisis estadístico realizado para comprobar si existen cambios significativos en los resultados que obedezcan a ciertas particularidades de la metodología.

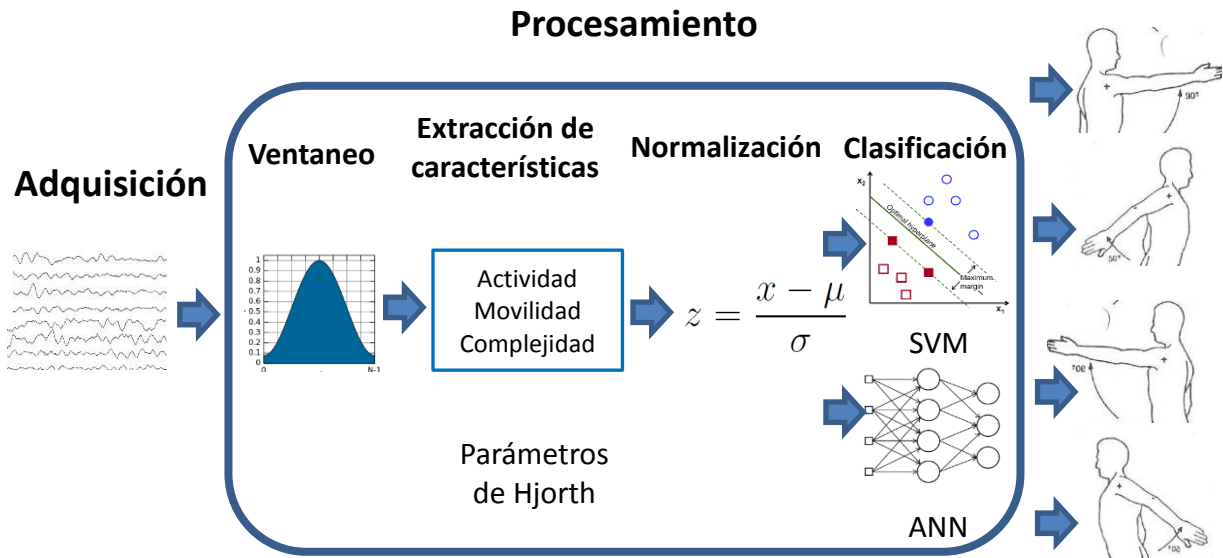


Fig. 3.1. Diagrama general de la solución propuesta.

3.2. Adquisición de datos

Se generó una base de datos de 10 sujetos de prueba, con edades de 25.6 ± 2.4 años, de los cuales 6 son varones y 4 mujeres. Los 10 sujetos son diestros. Se obtuvo el consentimiento informado de cada sujeto antes de realizar el estudio.

3.2.1. Criterios de inclusión y exclusión

a. Criterios de inclusión

- Haber dormido entre 6 y 8 horas la noche anterior a la prueba.

b. Criterios de exclusión

- Padecimiento de enfermedades neurológicas.
- Ingesta de alcohol 12 horas antes de la prueba.
- Consumo de estimulantes (café, tabaco, té, bebidas energizantes, chocolate, etc) 8 horas antes de la prueba.

- Abuso en la ingesta de carbohidratos y grasas 2 horas antes de la prueba.

3.2.2. Colocación de electrodos

Se utilizaron ocho canales monopolares del Estándar Internacional 10-20: Fp2, Fz, C3, C4, Cz, Pz, O1 y O2, además de AFz que fue empleado como electrodo de *bias*, para ello se utilizó una gorra E1-M de Electro-Cap ® con electrodos de Ag-AgCl. También se utilizó un electrodo reusable de copa como referencia, colocado en A2.




Fig. 3. 2. Posiciones de los electrodos utilizados. Los electrodos de señal se indican en color amarillo, el electrodo de *bias* en verde y el de referencia en color naranja.

Considerando que las ondas del EEG que cambian en mayor medida durante la ejecución de movimientos son μ y β , los canales C3, C4 y C5 fueron seleccionados debido a que se localizan encima de la corteza sensoriomotora que es donde se generan las ondas μ [26]. Fz y Pz fueron elegidos debido a que en sus posiciones se registran principalmente las ondas β [27].



Fig. 3. 3. Gorra con electrodos de Ag-AgCl de Electro-Cap ®

O1, O2 y Fp2 son de utilidad para realizar la comparación entre las pruebas con ojos abiertos y cerrados, debido a que O1 y O2 reflejan la actividad de la corteza visual [28] por medio de las ondas α , que de hecho interfieren en el mismo rango de las ondas μ y adquieren mayor amplitud con los ojos cerrados. En Fp2 es donde se observa en mayor medida la actividad del electrooculograma (EOG) registrado al parpadear. Esto implica resaltar las desventajas de ambas situaciones. Además, en un trabajo realizado en nuestro laboratorio por Márquez [29] se encontró evidencia de cambios de actividad eléctrica en los electrodos frontopolares durante el movimiento

3.2.3. Descripción de la prueba

El sujeto permanece sentado en un sillón, a 1.5 m de un monitor donde es desplegado un modelo virtual que recrea los movimientos a ejecutar (Fig. 3.4). El modelo fue desarrollado en nuestro laboratorio por Muñoz [30] por medio del editor *3D world* de Matlab ® y fue adaptado a las necesidades de este proyecto.

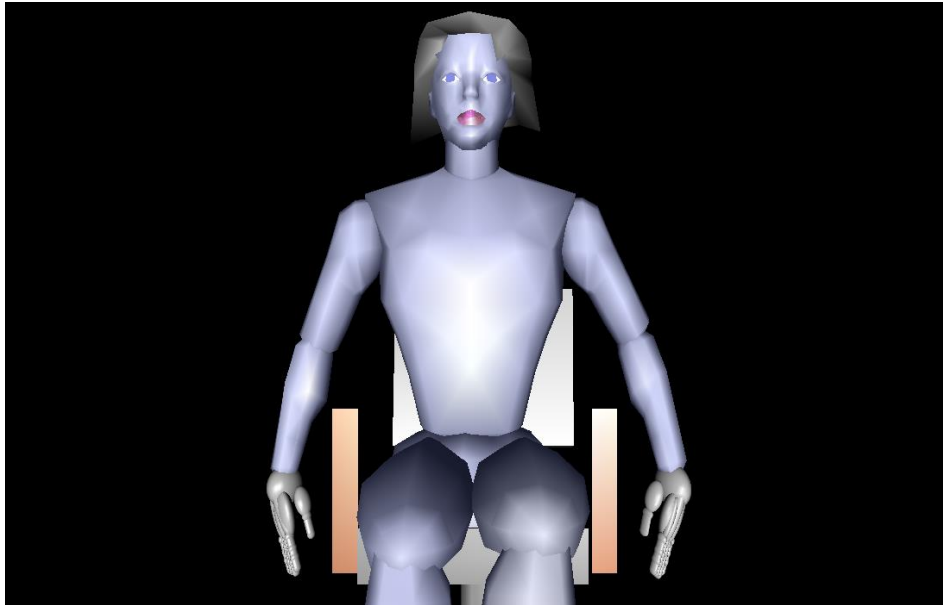


Fig. 3.4. Modelo virtual utilizado.

La prueba incluye cuatro secuencias de movimientos:

- 1) Flexión y extensión de hombros con ojos abiertos
- 2) Flexión y extensión de hombros con ojos cerrados
- 3) Pronación y supinación de muñecas con ojos abiertos
- 4) Pronación y supinación de muñecas con ojos cerrados

Cada secuencia se compone de 20 repeticiones por movimiento divididas en 10 repeticiones por cada extremidad. El orden en que se mueven las extremidades hasta completar las 20 repeticiones es aleatorio.

En la Fig. 3.5 se muestra un diagrama que muestra la distribución de tiempos por repetición, donde los símbolos con forma de altavoz representan indicadores auditivos de 0.5 s, el altavoz de mayor tamaño representa una grabación de voz que

indica la dirección de la extremidad que debe realizar el movimiento (izquierda o derecha) y $t_0 - t_5$ son los momentos en los que se almacenan marcadores de tiempo necesarios para la adecuada segmentación del registro. Los movimientos considerados agonistas son flexión y pronación y los antagonistas extensión y supinación, según la secuencia correspondiente.

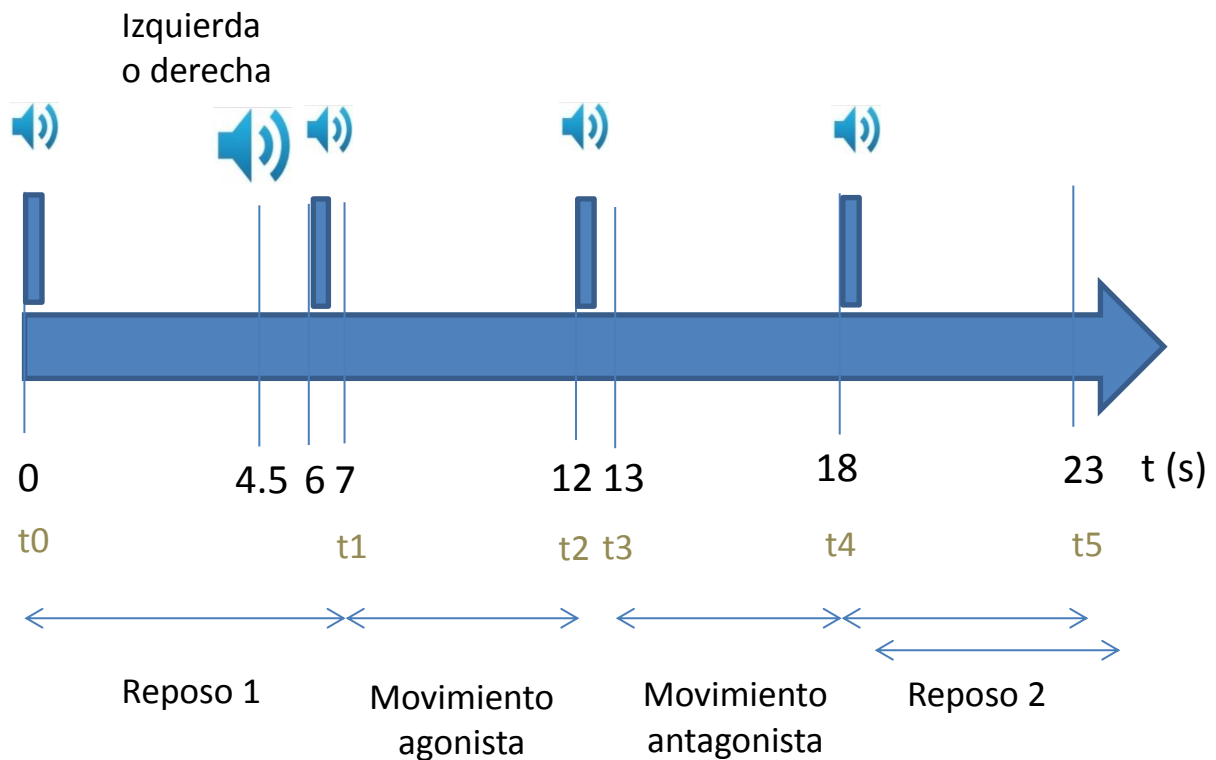


Fig. 3.5. Diagrama de distribución de tiempos por repetición.

El primer sonido indica el comienzo del estado de reposo, que para las secuencias 1 y 2 implica mantener los brazos extendidos hacia abajo, con las palmas orientadas hacia la línea media del cuerpo y para las secuencias 3 y 4 se apoyan los codos y los antebrazos en el sillón, con las palmas extendidas orientadas hacia arriba.

A los 4.5 s se escucha la grabación que indica la dirección de la extremidad que se deberá mover (izquierda o derecha) y a los 6 s el segundo sonido indica el inicio

del movimiento agonista, el modelo virtual comienza a moverse desde el segundo 7, a una velocidad de $\pi/10$ rad/s en el caso de flexión-extensión para completar 90° en 5 s y a $\pi/5$ rad/s en el caso de pronación-supinación para completar 180° en 5 s. Esos tiempos fueron propuestos con base en la duración con que se ha modelado la sincronización cerebral durante movimientos [31] y las velocidades únicamente para no generar fatiga en los sujetos de prueba.

A los 12 s, el tercer sonido indica el inicio del movimiento antagonista, para que a los 13 s el modelo virtual comience a moverse. A los 18 s se escucha el último sonido, indicando el inicio del segundo estado de reposo, en el cual se permite al usuario estirarse o hablar durante 5 s. Entre cada secuencia se dejó un tiempo de reposo de 3 min.

Las referencias [30-33] indican cuáles fueron los trabajos que sirvieron de punto de partida para generar esta propuesta de distribución de tiempos. Los tiempos fueron propuestos con base en la duración estimada de la respuesta a los estímulos en esos trabajos, al hecho de que la sincronización de la actividad cerebral se puede prolongar en un tiempo mayor a 3 s y en los tiempos de descanso necesarios para realizar repeticiones de un movimiento y su antagonista.

3.2.4. Sistema de adquisición

Se utilizó una tarjeta ADS1299EEG-FE de Texas Instruments ® (Fig. 3.6), que consiste en ocho canales diferenciales, cada uno con un filtro pasa bajas pasivo de primer orden con $f_c = 6.786$ kHz, un amplificador de ganancia programable, (PGA, *Programmable Gain Amplifier*) y un ADC $\Delta\Sigma$ de 24 bits. Para una revisión más detallada de las características técnicas de la tarjeta consulte el apéndice A.

La frecuencia de muestreo utilizada fue de 500 Hz y la ganancia de los PGA de todos los canales fue de 12. La tarjeta se alimenta con cuatro pilas AA.

El *software* original de la tarjeta se modificó utilizando LabView ® (versión 12.0) para poder sincronizar la adquisición de datos con el modelo virtual. Para ello se utilizó un *Matlab Script* para poder controlar todo el sistema desde LabView.



Fig. 3.6. Tarjeta ADS1299EEG-FE de Texas Instruments ®.

3.3. Análisis y procesamiento de datos

Todas las pruebas realizadas en esta etapa fueron implementadas a través de Matlab ® (versión R2013a).

3.3.1. Ventaneo

Después de separar los segmentos de señal correspondientes a la ejecución de movimientos, se procedió a elegir una función ventana para definir la información correspondiente a cada instancia al realizar la clasificación.

La duración de la ventana utilizada es de 500 ms y se seleccionó con base en la proporción entre el número de repeticiones por movimiento, la duración de cada repetición y el tamaño de la ventana en [4, 5, 12, 25].

Todos los trabajos descritos en la sección 2.5 se basaron en el uso de ventanas rectangulares. Aunque estas ventanas poseen una excelente resolución, son las más susceptibles a la fuga espectral.

Considerando que debido al compromiso entre resolución y rango dinámico las ventanas menos susceptibles a la fuga espectral poseen una resolución pobre, se propuso un tipo de ventana que no se encuentra en alguno de esos dos extremos, seleccionando la ventana Hamming, que además se utilizó en un trabajo de nuestro laboratorio realizado por Pla [34] donde utilizó esta ventana junto con los parámetros de Hjorth para lograr objetivos similares a los de este trabajo, por medio de señales electromiográficas (EMG).

En algunos estudios con metodología similar a los de este trabajo [35-37] se utilizaron ventanas que se traslapan entre sí. Esta opción fue descartada debido a que de esta manera existe redundancia en la información que ingresa al clasificador, pudiendo gran parte de ella formar parte tanto del conjunto de entrenamiento como del de prueba.

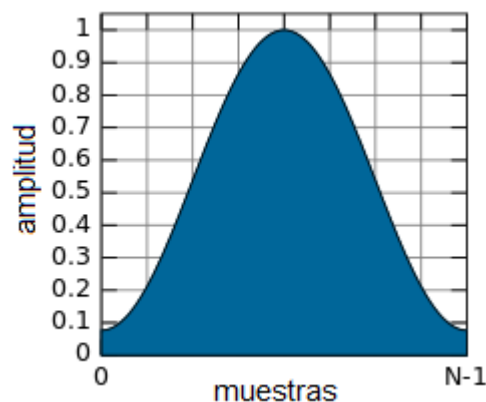


Fig. 3.7. Ventana Hamming.

Las señales asociadas a cada movimiento quedaron organizadas en arreglos de $8 \times 500 \times 100$, correspondientes a 8 canales, 500 muestras y 100 segmentos.

3.3.2. Extracción de características

Se calcularon los tres parámetros de Hjorth de cada segmento de 500 muestras, utilizando cada canal de manera separada, de esta manera se obtuvieron 8 valores de actividad, movilidad y complejidad por cada segmento, y fueron concatenados para obtener una matriz de 24 atributos por 100 instancias para cada movimiento.

3.3.3. Normalización

Para poder seleccionar el tipo de normalización más adecuado para nuestros datos se concatenaron las matrices de los distintos movimientos y se realizó un análisis de componentes principales (PCA, *Principal Components Analysis*) [38], graficando los tres componentes principales con mayor porcentaje de varianza. De esta manera, al aplicar distintas técnicas de normalización es posible observar a grandes rasgos cuál de ellas favorece más a la separación de las clases.

Se evaluaron dos técnicas de normalización: estandarización y centrado por medio de centroide.

La estandarización de un vector x se define de la siguiente forma:

$$z = \frac{x - \mu}{\sigma} \quad (16)$$

Donde μ es la media de x y σ es su desviación estándar. Para un caso multivariable se debe elegir respecto a cuál dimensión se van a estandarizar los datos.

El centroide de un conjunto multivariable de datos se define de la siguiente manera:

$$c = \sum_{i=1}^N m_i x_i \quad (17)$$

Donde x_i es el i -ésimo vector correspondiente al arreglo de N vectores y m se denomina vector de masas. Los valores de este vector se encuentran entre 0 y 1 su suma es igual a 1. De esta manera, cuando los datos son centrados respecto a la media, es equivalente a utilizar la fórmula del centroide con todos los valores del vector de masas iguales al recíproco del número de vectores $1/N$ [39]. En este trabajo el vector de masas corresponde a la varianza entre los atributos de cada instancia.

En las figuras 3.8 a 3.10 se muestra un ejemplo de las gráficas de los tres primeros componentes principales de matriz de parámetros de Hjorth de un sujeto de prueba que realizó movimientos de flexión y extensión de hombros con los ojos abiertos. Se analizan tres situaciones: con los datos sin normalizar, con estandarización y con centrado por medio del centroide.

Las gráficas de los componentes principales se utilizaron solamente como auxiliares visuales para observar las principales variaciones de los 24 atributos en una sola gráfica tridimensional. Dado que PCA es una técnica lineal no revela de manera total las variaciones existentes en el conjunto de datos y carece de un valor que cuantifique la separación de las clases. Sin embargo, se consideró un punto de partida para proponer técnicas de normalización al visualizar la distribución de las clases en la gráfica de los tres primeros componentes principales de los datos normalizados en comparación de los datos sin normalizar, descartando inicialmente otras técnicas como la transformación en vectores unitarios.




Fig. 3.8. Gráfica de los tres primeros componentes principales sin normalizar los datos. Los porcentajes de varianza de cada componente principal se muestran entre paréntesis.




Fig. 3.9. Gráfica de los tres primeros componentes principales estandarizando los datos. Los porcentajes de varianza de cada componente principal se muestran entre paréntesis.




Fig. 3.10. Gráfica de los tres primeros componentes principales centrando los datos por medio del centroide. Los porcentajes de varianza de cada componente principal se muestran entre paréntesis.

Con base en estas gráficas se propusieron las técnicas de estandarización y centrado con centroide debido a que indican una mejora en la separación de las clases respecto a la clase original. Lo anterior se comprobó posteriormente con los pasos descritos en la sección 3.4 utilizando máquinas de soporte vectorial (SVM, *Support Vector Machines*). En la tabla 3.1 se muestran los porcentajes de clasificación de cinco sujetos con los datos sin normalización, con estandarización y centrados respecto al centroide al clasificar movimientos de flexión – extensión de hombros, obteniendo mayores porcentajes de clasificación con los datos estandarizados.

La estandarización de los conjuntos de entrenamiento y de prueba se realizaron utilizando la media y la desviación estándar del conjunto de entrenamiento, para simular una situación donde esos valores no son conocidos para el conjunto de prueba.

Tabla 3.1. Porcentajes de clasificación de movimientos de flexión-extensión de hombros con distintos esquemas de normalización.

Sujeto	Sin normalización	Estandarización	Centroide
S1	82.56 ± 1.86%	91.10 ± 1.15%	85.15 ± 1.56%
S2	81.34 ± 1.18%	91.95 ± 0.90%	89.67 ± 0.95%
S3	83.65 ± 1.52%	93.80 ± 1.11%	94.47 ± 1.46%
S4	85.45 ± 1.86%	96.50 ± 0.99%	91.32 ± 1.93%
S5	89.25 ± 0.96%	94.70 ± 0.60%	88.16 ± 0.86%
Total	84.45 ± 3.08%	93.61 ± 2.16%	89.75 ± 3.48%

3.3.4. Clasificación

En las pruebas de clasificación de movimientos de los hombros, las cuatro clases fueron: flexión del hombro derecho, flexión del hombro izquierdo, extensión del hombro derecho y extensión del hombro izquierdo. Del mismo modo, durante la clasificación de movimientos de muñeca, las cuatro clases fueron: pronación de la muñeca derecha, pronación de la muñeca izquierda, supinación de la muñeca derecha y supinación de la muñeca izquierda.

3.3.4.1. Máquinas de soporte vectorial

Para definir los objetivos, cada instancia se etiquetó por medio de cuatro dígitos, identificando cada movimiento con una combinación de ceros y unos.

Con base en las gráficas obtenidas en la sección 3.3.3 se concluyó que un kernel lineal no sería útil, por lo que se propuso un kernel radial base que ya ha sido reportado en trabajos con metodología similar a este [40, 41].

En la selección de los hiperparámetros de la máquina se empleó un algoritmo de búsqueda de cuadrícula (*grid search*) que consiste en hacer todas las combinaciones posibles de un conjunto definido de valores de C y γ con el fin de comparar los

resultados de clasificación de una SVM para seleccionar la mejor combinación. Esta metodología se implementó con un k-fold con $k = 4$ utilizando el 75% de los datos para entrenamiento y el 25% para prueba (ver sección 3.4.1).

En la figura 3.11 se muestra la gráfica de búsqueda de cuadrícula con los porcentajes de clasificación obtenidos en la etapa de prueba con cada combinación de hiperparámetros para un sujeto de prueba. En ese caso la combinación de $C = 10$ y $\gamma = 1$ tuvo el mejor resultado para la clasificación de movimientos de pronación-supinación de muñeca con ojos abiertos.

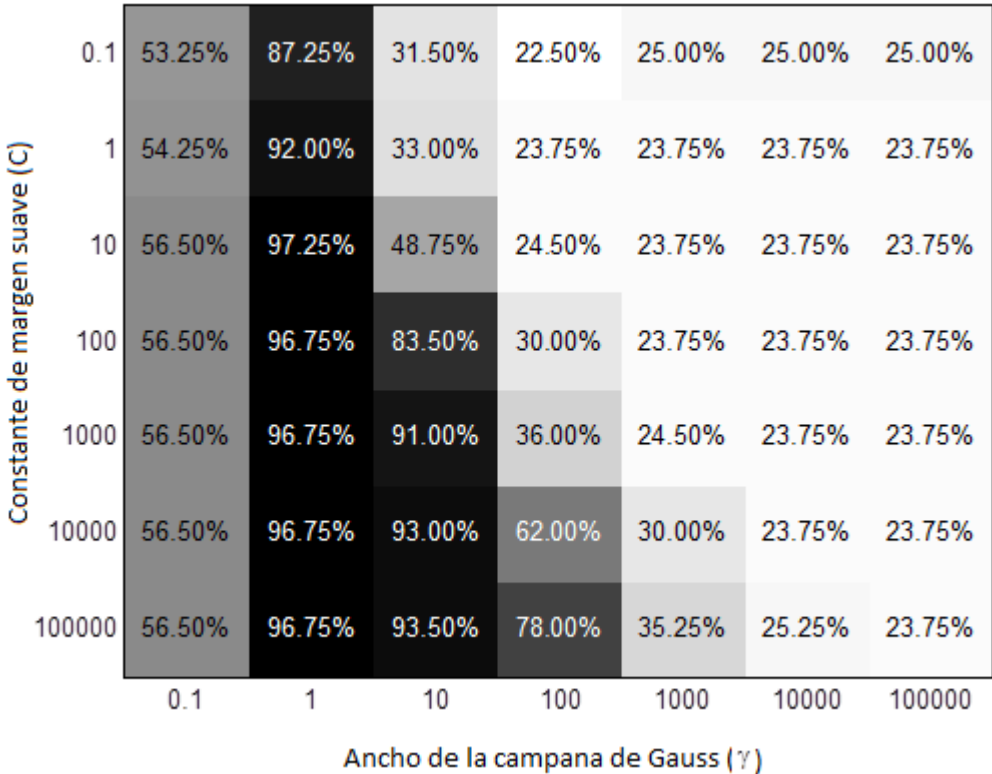


Fig. 3.11. Resultados de la búsqueda de cuadrícula para un sujeto de prueba, la mejor combinación de hiperparámetros es $C = 10$ y $\gamma = 1$.

De esta manera se identificaron los valores de C y γ que generaron mayores porcentajes de clasificación para cada sujeto de prueba y se seleccionaron los que se repetían un mayor número de veces. Las combinaciones de hiperparámetros

seleccionadas para la clasificación de flexión y extensión de hombro fueron: $C = 10000$, $\gamma = 10$ con ojos abiertos y $C = 1000$ y $\gamma = 1$ con ojos cerrados. Para pronación y supinación de muñeca fueron $C = 10$, $\gamma = 1$ con ojos abiertos y $C = 1000$ y $\gamma = 1$ con ojos cerrados

Para estas pruebas se utilizó la librería *The Spider* versión 1.71 para Matlab ® con un esquema AVA.

3.3.4.2. Redes neuronales artificiales

Se utilizó un MLP con una capa de salida que consiste en una sola neurona con función de activación lineal y dos capas ocultas, esto con el fin de utilizar como objetivos los números del 1 al 4 redondeando de esta manera el objetivo calculado, y mantener la propiedad de realizar dos proyecciones de los datos en nuevos espacios de características que otorga un MLP con una capa oculta sin la capa de salida propuesta.

Mediante el clásico proceso de prueba y error, se consiguió optimizar la arquitectura de las redes, utilizando como indicadores de desempeño el promedio y la desviación estándar de los porcentajes de clasificación obtenidos mediante la metodología descrita en la sección 3.4.1, optimizando inicialmente una arquitectura para cinco sujetos de prueba por separado y eligiendo después una arquitectura general con base en esas características (tabla 3.2). Las funciones de activación seleccionadas para las capas ocultas fueron: logarítmica sigmoidea y tangente sigmoidea respectivamente, con 24 neuronas para la capa de entrada.

El número de neuronas en la segunda capa oculta se adaptó para cada combinación de movimientos, utilizando 12 neuronas para los movimientos realizados con ojos abiertos, tanto flexión - extensión como pronación - supinación. Para los movimientos con ojos cerrados, se utilizaron 8 para flexión - extensión de hombro y 16 para pronación - supinación de muñeca.

Tabla 3.2. Arquitecturas de red optimizadas para clasificar movimientos de flexión-extensión de hombros.

Sujeto	Ojos abiertos		Ojos cerrados	
	Neuronas en capa oculta	Funciones de activación	Neuronas en capa oculta	Funciones de activación
S1	8	logsig/tansig	8	logsig/tansig
S2	8	logsig/tansig	12	logsig/tansig
S3	9	logsig/satlins	13	satlins/tansig
S4	13	tansig/tansig	12	tansig/tansig
S5	8	logsig/tansig	11	logsig/tansig

Las ANN se implementaron por medio de la toolbox *Neural Networks*, a través del algoritmo de gradiente conjugado escalado, 2000 épocas y el error cuadrático medio como función de costo con un umbral de 0.0001, dichos valores se modificaron progresivamente, hasta encontrar los más adecuados para todos los sujetos.

3.4. Validación

Las pruebas realizadas en esta etapa fueron implementadas a través de Matlab® (versión R2013a) exceptuando los análisis de la varianza (ANOVA, *Analysis of Variance*) que se realizaron en Microsoft Excel 2010.

3.4.1. Validación cruzada

Las instancias de cada clase fueron aleatorizadas de manera separada y se dividieron en cuatro porciones cada una para generar cuatro conjuntos equilibrados que permitieran realizar un k-fold con $k = 4$ utilizando uno de esos conjuntos para la prueba y los tres restantes para el entrenamiento, que son aleatorizados nuevamente. De esta manera se utiliza el 75% de la información para el

entrenamiento y el 25% para la prueba como se muestra en la figura 3.12, con cuatro iteraciones para garantizar que cada instancia formara parte del conjunto de prueba en una ocasión. La proporción de 75% - 25% se eligió debido a que se encuentra en un punto medio en cuanto al compromiso de sesgo y varianza que poseen los métodos de validación cruzada [42].

Una vez evaluados los resultados del clasificador se realizaron 10 repeticiones de este proceso para comprobar que los resultados fueran uniformes, garantizando un equilibrio estadístico de los experimentos realizados. Se reportaron los porcentajes de clasificación promedio de las 10 repeticiones del k-fold con su desviación estándar correspondiente.




Fig. 3.12. K-fold con $k = 4$. Se divide el total de entradas en cuatro porciones y cada una de ellas se utiliza como conjunto de prueba y las tres restantes como conjunto de entrenamiento.

3.4.2. Repetición de la prueba

Para garantizar la robustez de los modelos obtenidos se repitió la prueba a cuatro de los sujetos de la base de datos después de alrededor de 3 meses para poder comprobar si los resultados continúan dentro del rango definido por las desviaciones estándar calculadas.

3.4.3. ANOVA

ANOVA es una prueba estadística utilizada para comprobar si las medias de dos o más poblaciones son iguales. Esta condición es atribuida a la denominada *hipótesis nula*, cuando no se cumple, se acepta la *hipótesis alternativa* de que las medias son significativamente distintas. Al realizar el ANOVA se obtiene un valor denominado F y un valor F crítico, cuando F es mayor que F crítico, se acepta la hipótesis alternativa y por lo tanto las medias se consideran distintas, pudiendo comparar distintos factores que intervienen en un proceso para comprobar si implican diferencias significativas en su rendimiento, pudiendo monitorear varios factores en un mismo análisis y las relaciones entre ellos. En este trabajo, distintos factores son evaluados para comprobar si implican diferencias significativas en el rendimiento del clasificador.

Se realizó un ANOVA de dos factores con los porcentajes de clasificación obtenidos para comprobar si existe evidencia de mejoras significativas respecto al uso de SVM o ANN y los registros con ojos abiertos y cerrados.

Además se calcularon los valores de sensibilidad, especificidad y exactitud para cada clase y se realizó un ANOVA de un factor por cada valor para comprobar si alguno de los movimientos era más o menos favorecido que el resto durante su clasificación.

Esos valores se calculan de la siguiente forma:

$$\text{Sensibilidad} = \frac{VP}{VP + FN} \quad (18)$$

$$\text{Especificidad} = \frac{VN}{FP + FN} \quad (19)$$

$$Exactitud = \frac{VP + VN}{VP + FP + VN + FN} \quad (20)$$

Donde *VP* significa verdaderos positivos, *VN* verdaderos negativos, *FP* falsos positivos y *FN* falsos negativos.

En todos los ANOVA realizados en este trabajo a α se le asignó un valor de 0.05 para poder tener un intervalo de confianza del 95%.

3.4.4. Comparación de los parámetros de Hjorth con la dimensión fractal

Se seleccionó la dimensión fractal (FD, *Fractal Dimension*) como característica para comparar el rendimiento de los parámetros de Hjorth para clasificación de movimientos debido a que ambas se calculan en el dominio del tiempo, ambas tienen cierta conexión con el dominio de la frecuencia [7] y ambas se han comparado anteriormente con los parámetros de Hjorth en trabajos orientados al desarrollo de BCI, reportando superioridad de la FD en sus resultados [8, 9].

Para poder utilizar la FD en este trabajo, se realizó la implementación del método de Katz [43], que se define de la siguiente manera:

$$FD = \frac{\log_{10}L}{\log_{10}d} \quad (21)$$

Donde *L* se conoce como longitud y es la suma de las distancias euclidianas entre puntos subsecuentes de la señal, *d* se denomina diámetro y es igual a la mayor distancia euclidiana entre el primer punto de la señal y cualquier otro.

La FD puede ser utilizada para cuantificar la complejidad y autosimilaridad de una señal. Dado que la dimensión de un plano es igual a 2 y la dimensión de una línea es de 1, podemos esperar que la FD se encuentre siempre entre 1 y 2. En el caso del

EEG, entre más fluctuaciones tenga la señal, sería equivalente a que el plano aparezca “cubierto” y la FD aumentaría. Además la FD es capaz de identificar dos situaciones respecto al espectro de potencia del EEG: cuando la mayor parte de su energía se concentra en unos pocos componentes frecuenciales, la FD disminuye, y en caso de que la energía se distribuya uniformemente a través de sus componentes frecuenciales, la FD aumenta [44].

Resultados y discusión

En este capítulo se exponen y analizan los resultados obtenidos al realizar el procesamiento de las señales EEG de la base de datos generada y las pruebas de validación antes descritas. De esta manera se presentan al lector los datos que fundamentan las conclusiones obtenidas al realizar este trabajo.

4.1. Porcentajes de clasificación

En las tablas 4.1 y 4.2 se muestran los porcentajes de clasificación obtenidos en la fase de prueba, con cada clasificador y con registros con ojos abiertos y cerrados.

Tabla 4.1. Porcentajes de clasificación para flexión-extensión de hombros.

Sujeto	Ojos abiertos		Ojos cerrados	
	SVM	ANN	SVM	ANN
S1	91.10 ± 1.15%	87.87 ± 2.09%	94.52 ± 0.97%	92.15 ± 1.60%
S2	91.95 ± 0.90%	95.65 ± 1.19%	98.58 ± 0.78%	96.85 ± 1.09%
S3	93.80 ± 1.11%	93.40 ± 1.74%	97.25 ± 0.69%	94.45 ± 1.48%
S4	96.50 ± 0.99%	97.32 ± 0.66%	97.43 ± 0.69%	94.87 ± 1.39%
S5	94.70 ± 0.60%	95.55 ± 1.23%	92.67 ± 0.91%	96.13 ± 0.88%
S6	93.35 ± 0.91%	96.15 ± 0.69%	94.95 ± 0.84%	93.55 ± 1.05%
S7	93.02 ± 1.01%	92.90 ± 1.68%	95.60 ± 0.86%	93.70 ± 1.09%
S8	88.12 ± 1.05%	91.20 ± 1.25%	95.68 ± 0.91%	95.50 ± 1.21%
S9	94.45 ± 0.79%	92.80 ± 1.10%	95.20 ± 0.84%	95.55 ± 0.63%
S10	92.03 ± 1.10%	92.45 ± 1.55%	96.50 ± 1.09%	94.58 ± 0.99%
Total	92.90 ± 2.29%	93.53 ± 2.78%	95.84 ± 1.68%	94.73 ± 1.37%

Tabla 4.2. Porcentajes de clasificación para pronación-supinación de muñecas.

Sujeto	Ojos abiertos		Ojos cerrados	
	SVM	ANN	SVM	ANN
S1	96.65 ± 0.91%	96.80 ± 0.63%	98.75 ± 0.65%	97.32 ± 0.88%
S2	97.15 ± 0.60%	95.38 ± 0.67%	98.20 ± 0.73%	95.52 ± 1.08%
S3	92.62 ± 0.65%	93.93 ± 1.00%	97.80 ± 0.73%	94.25 ± 1.30%
S4	90.35 ± 0.80%	88.55 ± 1.38%	86.83 ± 1.26%	87.90 ± 1.24%
S5	96.15 ± 1.19%	93.20 ± 1.46%	98.28 ± 0.53%	95.52 ± 1.15%
S6	96.75 ± 0.81%	95.20 ± 0.94%	93.65 ± 0.90%	93.38 ± 0.87%
S7	96.82 ± 0.82%	93.90 ± 1.06%	95.43 ± 0.82%	90.25 ± 1.07%
S8	97.92 ± 0.39%	95.85 ± 0.72%	96.55 ± 0.56%	93.95 ± 1.19%
S9	82.43 ± 1.55%	88.08 ± 1.16%	97.70 ± 0.62%	95.70 ± 1.12%
S10	95.07 ± 0.67%	93.95 ± 1.49%	97.15 ± 0.52%	95.72 ± 0.96%
Total	94.19 ± 4.74%	93.48 ± 2.93%	96.03 ± 3.58%	93.95 ± 2.85%

Los resultados de promedio y desviación estándar entre sujetos se pueden apreciar de mejor manera en una gráfica de barras de error como la que se muestra en la figura 4.1.

En los resultados de flexión - extensión de hombros, los porcentajes de clasificación son más altos y las dispersiones menores cuando se utilizan los registros con ojos cerrados, sin embargo, estas diferencias van de 1% a 3% aproximadamente. En los resultados de pronación - supinación no se observa este patrón. Los porcentajes promedio de ambas combinaciones de movimientos son similares, mientras que se observan dispersiones mayores en las pruebas de pronación - supinación de muñeca.




Fig. 4.1. Comparación entre porcentajes de clasificación. a) Flexión - extensión de hombros. b) Pronación - supinación de muñecas.

Con un gráfico de error no es posible asegurar que las diferencias de rendimiento observadas entre clasificadores y registros de ojos abiertos y cerrados sean estadísticamente significativas, debido a eso se realizó un ANOVA de dos factores a los resultados obtenidos.

El ANOVA de dos factores realizado a los resultados de flexión – extensión de hombros asigna un valor F de 0.129 al clasificador utilizado, de 9.687 al hecho de tener los ojos abiertos o cerrados y de 1.695 a la interacción de ambos factores, siendo 4.113 el valor F crítico para los tres casos. Debido a esto, la hipótesis alternativa es rechazada para el clasificador utilizado y para la combinación de ambos factores, indicando igualdad en sus medias y se acepta para la condición de los ojos durante el registro, indicando diferencias significativas en sus medias. Esto implica que el hecho de tener los ojos abiertos o cerrados en estos resultados influye considerablemente.

En el caso de pronación y supinación de muñeca, se obtuvieron: $F = 0.318$ para el clasificador, $F = 0.229$ para los ojos y $F = 0.550$ para ambos factores, con F crítico = 4.113. La hipótesis nula es aceptada en los tres casos. Esto indica que ni el clasificador utilizado ni el hecho de tener los ojos abiertos o cerrados implica cambios significativos.

Con base en los resultados de los ANOVA realizados, se considera similar el rendimiento de los clasificadores basados en SVM o ANN pero debido a la diferencia en ambos conjuntos de movimientos no se considera que exista evidencia suficiente para considerar que existan diferencias significativas al tener los ojos abiertos o cerrados durante la prueba, esta diferencia se atribuye más bien al hecho de que en los primeros movimientos la retroalimentación visual que proporciona el modelo virtual se vuelve más importante para controlar la velocidad a la que se debe realizar el movimiento para que la flexión termine en el mismo punto en cada repetición, esto se observó durante la generación de la base de datos. En el segundo par de movimientos se observó que la retroalimentación visual es menos crítica para los sujetos de prueba.

4.2. Sensitividad, especificidad y exactitud

Los resultados promedio entre sujetos de sensitividad, especificidad y exactitud para cada movimiento se pueden apreciar en las figuras 4.2 y 4.3.

En esas gráficas no se observa que alguno de los movimientos tenga promedios mayores o dispersiones menores de manera considerable al compararlo con el resto, por lo que parece que ningún movimiento es más o menos favorecido que el resto al momento de su clasificación.

El ANOVA realizado a cada valor comprueba ese punto, ya que los valores de F para sensitividad, especificidad y exactitud para flexión - extensión de hombros fueron: 0.206, 1.561 y 0.865 respectivamente, y para pronación - supinación de muñecas fueron 0.956, 1.624 y 1.296, con F crítico de 3.490 en ambos casos.

La hipótesis nula es aceptada en todos los casos, indicando que no existen diferencias significativas en las medias de los resultados de cada movimiento.


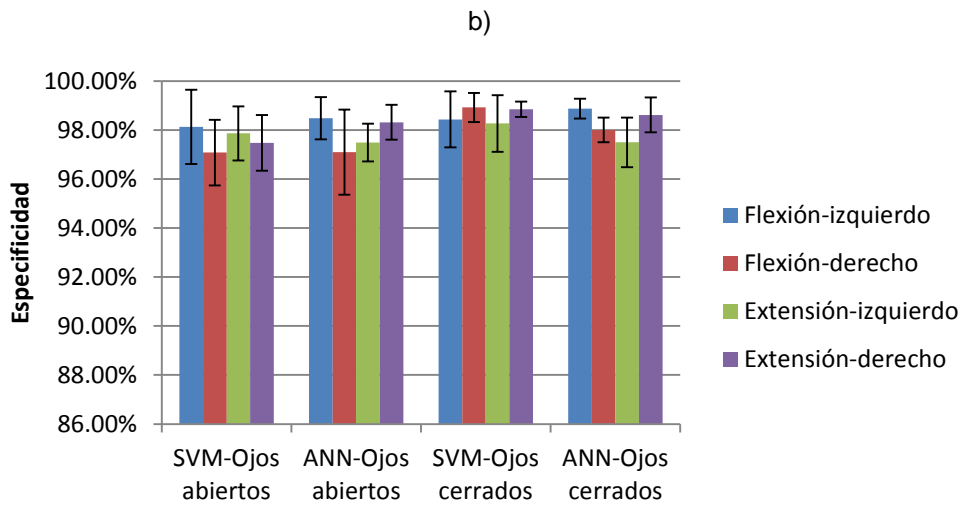
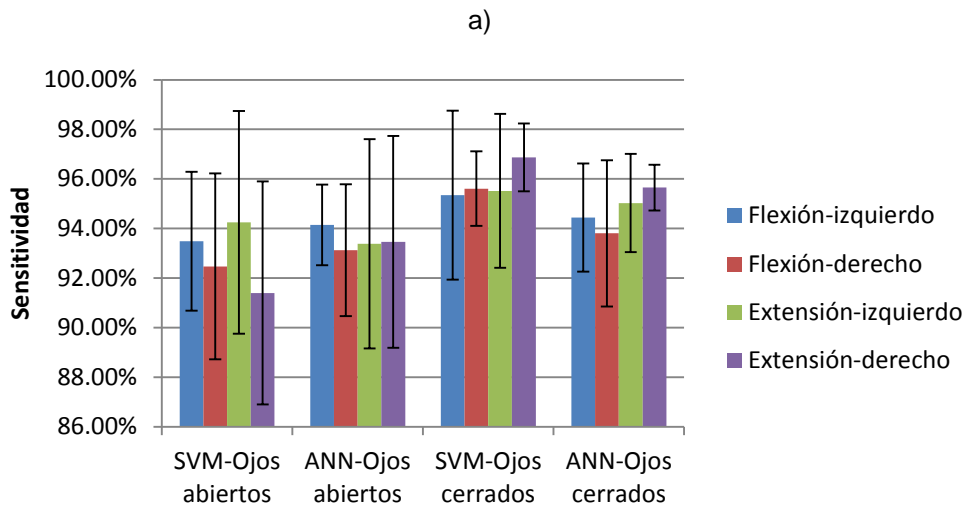


Fig. 4.2. Sensitividad, especificidad y exactitud para flexión - extensión de hombros.

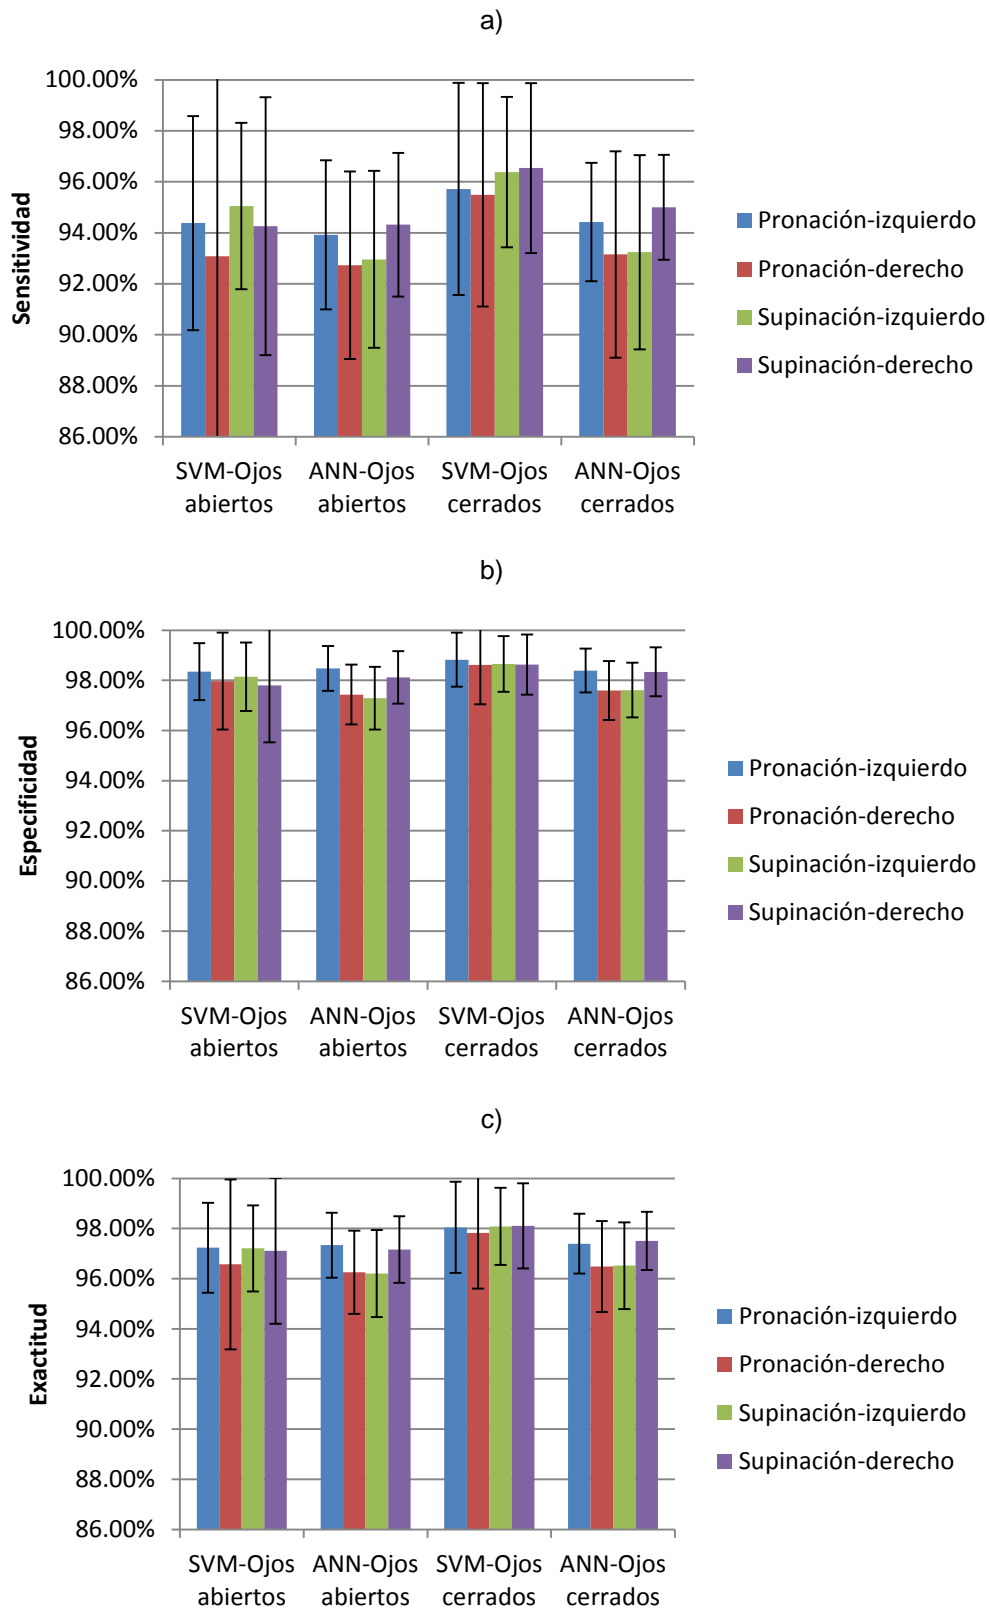


Fig. 4.3. Sensibilidad, especificidad y exactitud para pronación - supinación de muñecas.

4.3. Repetición de la prueba

Los porcentajes de clasificación obtenidos al repetir la prueba a los sujetos S1, S3, S4 y S5 se muestran en las tablas 4.3 y 4.4.

Tabla 4.3. Resultados de los movimientos de flexión-extensión de hombros al repetir la prueba a cuatro de los sujetos de la base de datos.

Sujeto	Ojos	Primera prueba		Segunda prueba	
		SVM	ANN	SVM	ANN
S1	Abiertos	91.10 ± 1.15%	87.87 ± 2.09%	87.56 ± 1.34%	86.16 ± 0.95%
	Cerrados	94.52 ± 0.97%	92.15 ± 1.06%	90.46 ± 1.68%	89.26 ± 1.46%
S3	Abiertos	93.80 ± 1.11%	93.40 ± 1.74%	94.77 ± 0.86%	95.12 ± 0.84%
	Cerrados	97.25 ± 0.69%	94.45 ± 1.48%	95.40 ± 1.18%	93.92 ± 1.38%
S4	Abiertos	96.50 ± 0.99%	97.32 ± 0.66%	90.35 ± 1.09%	94.37 ± 1.04%
	Cerrados	97.43 ± 0.69%	94.87 ± 1.39%	92.46 ± 1.59%	90.97 ± 1.40%
S5	Abiertos	94.70 ± 0.60%	95.55 ± 1.23%	94.83 ± 0.90%	95.17 ± 1.05%
	Cerrados	92.67 ± 0.91%	96.13 ± 0.88%	92.62 ± 1.24%	92.02 ± 1.35%

Tabla 4. 4. Resultados de los movimientos de pronación-supinación de muñecas al repetir la prueba a cuatro de los sujetos de la base de datos.

Sujeto	Ojos	Primera prueba		Segunda prueba	
		SVM	ANN	SVM	ANN
S1	Abiertos	97.45 ± 0.40%	96.80 ± 0.63%	87.52 ± 0.84%	90.46 ± 0.76%
	Cerrados	98.75 ± 0.65%	97.32 ± 0.88%	94.26 ± 1.45%	92.35 ± 1.05%
S3	Abiertos	95.70 ± 0.86%	93.93 ± 1.00%	96.75 ± 1.00%	94.47 ± 0.62%
	Cerrados	97.80 ± 0.73%	94.25 ± 1.30%	98.48 ± 0.65%	96.25 ± 1.48%
S4	Abiertos	91.40 ± 0.94%	88.55 ± 1.38%	92.15 ± 0.84%	86.52 ± 1.26%
	Cerrados	86.83 ± 1.26%	87.90 ± 1.24%	85.26 ± 1.59%	90.23 ± 1.15%
S5	Abiertos	97.10 ± 0.59%	93.20 ± 1.46%	97.62 ± 0.48%	94.53 ± 1.13%
	Cerrados	98.28 ± 0.53%	95.52 ± 1.15%	96.65 ± 0.69%	95.20 ± 0.86%

En los sujetos S3 y S5 los porcentajes de clasificación de ambas pruebas se mantienen en rangos similares, siendo las mayores variaciones de alrededor del 2% y se encuentran dentro del rango delimitado por las desviaciones estándar mostradas en la sección 4.1. En los resultados de los sujetos S1 y S4 existe un comportamiento distinto, pues mientras para S1 todos los porcentajes son menores en la segunda prueba, existiendo una variación máxima cercana al 10% y para S4 existen ambos patrones.

Dicho comportamiento se puede atribuir a las siguientes razones:

Las variaciones más pronunciadas pueden ser causadas por cambios en distintas variables que afectan al registro EEG y son difíciles de controlar, como la sudoración, falta de concentración, y el estado anímico del sujeto de prueba, pues como se comentó anteriormente en el EEG se registra información de múltiples tareas adicionales a las funciones motora. Debido a esto no podríamos garantizar de manera infalible que en cada sesión los distintos sujetos de prueba obtengan exactamente los mismos resultados.

Sin embargo, esto no quiere decir que el modelo deje de ser válido conforme termina cada sesión, ya que las características de los clasificadores se seleccionaron con el fin de adecuarse a los registros de 10 sujetos distintos, debido a esto la arquitectura de la ANN y los parámetros de la SVM poseen cierta robustez y si a esto le sumamos el hecho de que las características generales del modelo son comunes a todos los sujetos pero las fases de entrenamiento y prueba se realizan de manera separada, se puede esperar que los resultados se mantengan en cierto rango.

4.4. Comparación con la literatura

El trabajo más adecuado para realizar una comparación con esta metodología es el realizado en 2015 por S. K. Bashar y M. I. H. Bhuiyan [5], pues es el único caso encontrado en la literatura que tiene los siguientes puntos en común con este trabajo:

- Se realiza identificación de movimientos de extremidades superiores a partir de EEG registrados durante su ejecución.
- Se clasifican 4 movimientos simultáneamente, teniendo dos pares de movimientos agonistas y antagonistas, realizados por cada una de las extremidades superiores.

Los movimientos clasificados en ese estudio son los mismos que se describieron en la primera parte del protocolo de este trabajo: flexión de hombro izquierdo, flexión de hombro derecho, extensión de hombro izquierdo y extensión de hombro derecho. Los registros fueron realizados con un solo sujeto con ojos cerrados durante la prueba.

El porcentaje de clasificación reportado es de 92.84%. En este trabajo, se utilizó una base de datos de 10 sujetos y se obtuvo $95.84 \pm 1.68\%$ con SVM y $94.73 \pm 1.37\%$ con ANN utilizando los registros realizados con ojos cerrados.

Con base en esos resultados, se podría asegurar que la metodología propuesta en este trabajo tiene un rendimiento similar al del trabajo comparado, con respaldo de más pruebas de validación. Además, cabe mencionar que la etapa de extracción de características tiene un costo computacional significativamente menor, debido a que este trabajo se basa únicamente en el cálculo de los parámetros de Hjorth y su estandarización, a diferencia del uso de la WPT seguido de la FFT y el cálculo de la curtosis de los coeficientes de Fourier.

4.5. Comparación con el uso de la dimensión fractal

En la tabla 4.5 se muestran los resultados obtenidos al realizar la clasificación con FD como características y SVM como clasificador.

Los hiperparámetros seleccionados para flexión y extensión fueron: $C = 1000$, $\gamma = 100$ con ojos abiertos y $C = 100$ y $\gamma = 1$ con ojos cerrados. Para pronación y supinación de muñeca fueron $C = 1000$, $\gamma = 1$ tanto con ojos abiertos como ojos cerrados. La técnica de normalización elegida también fue la estandarización debido un proceso similar al descrito en la sección 3.3.3.

Tabla 4.5. Porcentajes de clasificación obtenidos utilizando FD como características.

Sujeto	Flexión - extensión		Pronación - supinación	
	Ojos abiertos	Ojos cerrados	Ojos abiertos	Ojos cerrados
S1	76.40 ± 1.70%	88.87 ± 1.11%	87.10 ± 1.55%	90.88 ± 1.56%
S2	74.57 ± 1.72%	85.88 ± 0.86%	87.85 ± 1.43%	86.00 ± 0.59%
S3	84.45 ± 1.58%	87.55 ± 1.69%	82.10 ± 1.37%	92.17 ± 0.92%
S4	92.15 ± 1.37%	87.45 ± 1.33%	72.48 ± 1.75%	74.57 ± 1.46%
S5	80.35 ± 1.13%	83.80 ± 1.83%	84.38 ± 1.88%	88.12 ± 1.43%
S6	69.70 ± 1.36%	81.58 ± 1.38%	78.85 ± 1.91%	75.95 ± 2.16%
S7	69.85 ± 1.79%	82.83 ± 1.33%	52.73 ± 1.32%	50.23 ± 1.51%
S8	85.82 ± 1.48%	93.82 ± 0.96%	95.40 ± 1.00%	92.52 ± 1.40%
S9	89.28 ± 0.68%	92.13 ± 0.92%	66.23 ± 1.62%	92.38 ± 1.16%
S10	88.38 ± 1.06%	90.75 ± 0.96%	89.75 ± 0.97%	92.52 ± 0.79%
Total	81.10 ± 8.15%	87.47 ± 4.04%	79.69 ± 12.63%	83.53 ± 13.51%

En la figura 4.4 se observa la comparación de porcentajes de clasificación al utilizar parámetros de Hjorth y FD como características. En todos los casos se obtuvieron porcentajes de clasificación menores y dispersiones mayores utilizando FD. Se realizó un ANOVA de un factor para respaldar que la diferencia de las medias de los resultados de ambas características es estadísticamente significativa y se obtuvo un valor F de 42.759 que superó por más de 7 veces al valor F crítico de 5.988.

La diferencia de rendimientos se puede atribuir a la mayor susceptibilidad de la FD respecto al ruido [44], considerando que las señales utilizadas en este trabajo solamente pasan a través del filtro pasa bajas contra interferencia electromagnética que tiene la tarjeta, con $f_c = 6.786$ kHz, pero no se realiza un filtrado en la banda correspondiente al EEG. Esto implica una ventaja de los parámetros de Hjorth, ya que además de las ventajas que ya se han mencionado, permiten omitir un bloque de

filtrado pasa-banda y siguen otorgando información general útil en el dominio de la frecuencia.

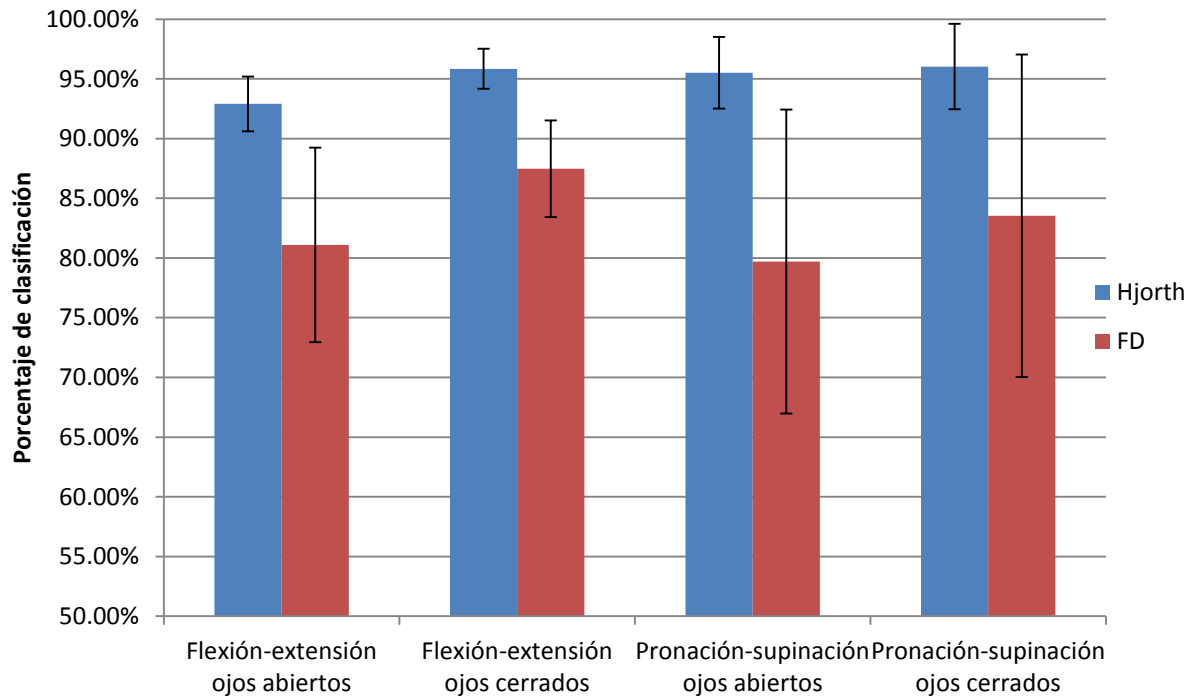


Fig. 4.4. Comparación entre parámetros de Hjorth y FD.

Conclusiones y perspectivas

El objetivo de este trabajo fue proponer una metodología que permitiera evaluar el desempeño de los parámetros de Hjorth como indicadores de actividad motora por medio de la actividad eléctrica cerebral.

La metodología propuesta consiste en el registro simultáneo de ocho canales EEG durante la ejecución de movimientos, la extracción de los tres parámetros de Hjorth de cada canal después de un proceso de ventaneo, la estandarización de los valores obtenidos y el uso de SVM y ANN como clasificadores. Distintos criterios y técnicas fueron utilizados para encontrar los parámetros adecuados para cada una de estas etapas. Además se diseñó un protocolo de adquisición de EEG y se generó una base de datos de 10 sujetos con registros realizados con ojos abiertos y cerrados.

Con base en los resultados expuestos en el capítulo VI se presentan las siguientes conclusiones:

El protocolo de adquisición propuesto permite el registro adecuado de la señal EEG y los registros obtenidos contienen información útil para la clasificación de movimientos de extremidades superiores.

El rendimiento de SVM y ANN en esta aplicación puede considerarse similar debido a que el ANOVA reveló que no existen diferencias estadísticamente significativas en sus resultados. Además los fundamentos matemáticos de ambos clasificadores tienen características en común a pesar de que su optimización obedezca a algoritmos que funcionan de manera distinta.

Sin embargo, un punto importante a considerar es el costo computacional de cada clasificador, sobre todo en este trabajo donde la finalidad de utilizar los parámetros de Hjorth es la optimización de ese aspecto. Al medir la duración total de las 10 repeticiones del k-fold con cada clasificador se observó que las pruebas con ANN duran aproximadamente 5 veces más que las de SVM. Por esta razón se recomendaría el uso de SVM para esta aplicación específica.

En cuanto a las diferencias de los resultados obtenidos con los registros realizados con ojos abiertos y cerrados, se observaron promedios mayores y dispersiones menores en los porcentajes de clasificación cuando se mantienen los ojos cerrados para los movimientos de flexión y extensión de hombros, mientras que en los de pronación y supinación de muñecas no se cumplió este patrón.

El análisis estadístico indica que existe evidencia de cambios significativos cuando se realizan los movimientos de flexión y extensión de hombros pero no en los de pronación y supinación de muñecas, por lo que no se encontró suficiente evidencia de que la condición de ojos abiertos o cerrados sea más favorable para el análisis de movimiento en general.

Para esta aplicación, el desempeño de los parámetros de Hjorth como característica para clasificación de movimientos resultó ser mejor que el de la FD, que además de otorgar las ventajas que estos poseen ya ha sido comparada con ellos en otras aplicaciones orientadas al desarrollo de BCI reportando un rendimiento superior. Con base en la metodología de este trabajo se podría atribuir a los parámetros de Hjorth una ventaja en cuanto a la capacidad de extraer información general del dominio de la frecuencia sin que se haya realizado un filtrado minucioso de las señales.

En este trabajo se utilizó un enfoque que propone modelos de SVM y ANN con los mismos hiperparámetros y arquitectura de red para todos los sujetos de la base de datos y permite la adecuación a cada sujeto en las fases de entrenamiento y

prueba de manera separada. Debido a que el EEG es una señal estocástica y no estacionaria y con grandes variaciones entre personas, no sería posible establecer un modelo totalmente genérico capaz de funcionar con información proveniente de varios sujetos y funcionar sin tener que adaptarse a cada usuario, sin embargo, los modelos propuestos en esta tesis podrían adaptarse a sujetos de prueba que no hayan formado parte de la base de datos mediante una previa etapa de entrenamiento, sin tener que repetir los pasos para seleccionar hiperparámetros o arquitectura de red.

La metodología propuesta permitió obtener valores de dispersión entre sujetos de alrededor de la mitad de los reportadas por el estudio anterior donde se aplicaron los parámetros de Hjorth a la identificación de movimientos, y mantuvo las variaciones entre repeticiones de los mismos sujetos con desviaciones estándar menores al 1% en la mayoría de los casos, siendo la mayor de 2.09%.

Las pruebas realizadas permiten afirmar que los parámetros de Hjorth son una herramienta adecuada para la identificación de movimientos a partir de las señales EEG. El bajo costo computacional del cálculo de estos parámetros podría permitir la mejora de los tiempos de respuesta de los dispositivos diseñados para ser controlados por medio de la actividad cerebral.

Para poder continuar avanzando sobre la línea de investigación de este trabajo, los siguientes aspectos deberán ser considerados:

- Incluir en la base de datos señales registradas durante el proceso de imaginación motora.
- Realizar pruebas utilizando el estado transitorio de las señales, al momento de presentar la desincronización relacionada con la actividad motora.

- Llevar a cabo una comparación de SVM y ANN con un clasificador que implique menor costo computacional.
- Reducir el número de canales utilizados para el registro de EEG e incrementar el número de movimientos analizados.
- Enriquecer la base de datos utilizando una mayor cantidad de sujetos de prueba, analizando si existen diferencias significativas en sujetos con edades menos uniformes.
- Encontrar una metodología de registro de EEG que reduzca la incomodidad causada por el contacto de la gorra con electrodos.

Características de la tarjeta ADS1299EEG-FE

En esta sección se enlistan las características técnicas más importantes de la tarjeta de adquisición utilizada para el registro de las señales EEG:

- Voltaje de alimentación: 5.5 V - 15 V
- Corriente máxima: 500 mA
- Ocho canales diferenciales, cada uno con un ADC $\Delta\Sigma$ de 24 bits
- Filtros pasa bajas pasivos de primer orden con $f_c = 6.786$ kHz
- PGA con ganancias de 1, 2, 4, 8, 12 y 24.
- Frecuencia de muestreo de 250 Hz a 16 kHz.
- Rango de temperatura de operación: - 40°C - 85°C.

Con los valores de ganancia y frecuencia de muestreo utilizados en este trabajo ($G = 12$ y $f_s = 500$ Hz) se tienen las siguientes características:

- Número de bits efectivos: 20 bits
- Nivel de ruido a la entrada: 1.61 μVpp

Referencias

- [1] P. L. Nunez and R. B. Silberstein, "On the relationship of synaptic activity to macroscopic measurements: does co-registration of EEG with fMRI make sense?," *Brain topography*, vol. 13, pp. 79-96, 2000.
- [2] F. Bager, F. Shaw, A. Tavener, M. Loeffen, and C. Devine, "Comparison of EEG and ECoG for detecting cerebrocortical activity during slaughter of calves," *Meat science*, vol. 27, pp. 211-225, 1990.
- [3] T. M. Vaughan, W. Heetderks, L. Trejo, W. Rymer, M. Weinrich, M. Moore, *et al.*, "Brain-computer interface technology: a review of the Second International Meeting," ed, 2003.
- [4] A. Aowlad, M. W. Rahman, and M. A. Riheen, "Left and Right Hand Movements EEG Signals Classification Using Wavelet Transform and Probabilistic Neural Network," *International Journal of Electrical and Computer Engineering*, vol. 5, p. 92, 2015.
- [5] S. K. Bashar and M. I. H. Bhuiyan, "Identification of arm movements using statistical features from EEG signals in wavelet packet domain," in *Electrical Engineering and Information Communication Technology (ICEEICT), 2015 International Conference on*, 2015, pp. 1-5.
- [6] B. Hjorth, "EEG analysis based on time domain properties," *Electroencephalography and clinical neurophysiology*, vol. 29, pp. 306-310, 1970.
- [7] M. Sebastián and M. Navascués, "A relation between fractal dimension and Fourier transform–electroencephalographic study using spectral and fractal

- parameters," *International Journal of Computer Mathematics*, vol. 85, pp. 657-665, 2008.
- [8] R. Boostani and M. H. Moradi, "A new approach in the BCI research based on fractal dimension as feature and Adaboost as classifier," *Journal of Neural Engineering*, vol. 1, p. 212, 2004.
- [9] J. N. da Cruz, Z. Wang, C. M. Wong, and F. Wan, "Single-trial detection of error-related potential by one-unit SOBI-R in SSVEP-based BCI," in *International Symposium on Neural Networks*, 2014, pp. 524-532.
- [10] R. C. Caracillo and M. C. F. Castro, "Classification of executed upper limb movements by means of EEG," in *Biosignals and Biorobotics Conference (BRC), 2013 ISSNIP*, 2013, pp. 1-6.
- [11] A. Mohamed, T. Marwala, and L. John, "Single-trial EEG discrimination between wrist and finger movement imagery and execution in a sensorimotor BCI," in *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE*, 2011, pp. 6289-6293.
- [12] H. A. Shedeed, M. F. Issa, and S. M. El-Sayed, "Brain EEG signal processing for controlling a robotic arm," in *Computer Engineering & Systems (ICCES), 2013 8th International Conference on*, 2013, pp. 152-157.
- [13] W. O. Tatum IV, *Handbook of EEG interpretation*. New York, N.Y: Demos Medical Publishing, 2014, pp. 31-37.
- [14] H. Berger, "Über das elektrenkephalogramm des menschen," *European Archives of Psychiatry and Clinical Neuroscience*, vol. 87, pp. 527-570, 1929.

- [15] J. G. Webster, *Medical Instrumentation: Application and Design*. Hoboken, NJ: Wiley, 2009, ch. 4, pp. 163-172.
- [16] A. C. Guyton and J. E. Hall, *Tratado de fisiología médica*, Barcelona, España: Elsevier, 2006, ch. 59, pp. 724-725.
- [17] W. Freeman and R. Q. Quiroga, *Imaging brain function with EEG: advanced temporal and spatial analysis of electroencephalographic signals*: Springer Science & Business Media, 2012.
- [18] R. Nashmi, A. J. Mendonça, and W. A. MacKay, "EEG rhythms of the sensorimotor region during hand movements," *Electroencephalography and clinical neurophysiology*, vol. 91, pp. 456-467, 1994.
- [19] D. Popivanov, A. Mineva, and I. Krekule, "EEG patterns in theta and gamma frequency range and their probable relation to human voluntary movement organization," *Neuroscience Letters*, vol. 267, pp. 5-8, 1999.
- [20] H. H. Jasper, "The ten twenty electrode system of the international federation," *Electroencephalography and clinical neurophysiology*, vol. 10, pp. 371-375, 1958.
- [21] B. E. Boser, I. M. Guyon, and V. N. Vapnik, "A training algorithm for optimal margin classifiers," in *Proceedings of the fifth annual workshop on Computational learning theory*, 1992, pp. 144-152.
- [22] A. Ben-Hur and J. Weston, "A user's guide to support vector machines," *Data mining techniques for the life sciences*, pp. 223-239, 2010.
- [23] R. Rifkin and A. Klautau, "In defense of one-vs-all classification," *Journal of machine learning research*, vol. 5, pp. 101-141, 2004.

- [24] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *The bulletin of mathematical biophysics*, vol. 5, pp. 115-133, 1943.
- [25] A. Schlögl, B. Schack, G. Florian, K. Lugger, M. Pregenzer and G. Pfurtscheller, "Classification of single trial EEG: A comparison of different parameters," *Qualitative and topological EEG and MEG analysis*, in *Proc. Third Int Hans Berger Congress*, pp. 266-268.
- [26] G. Pfurtscheller, C. Brunner, A. Schlögl and F. L. Da Silva, "Mu rhythm (de) synchronization and EEG single-trial classification of different motor imagery tasks," *NeuroImage*, vol. 31, pp. 153-159, 2006.
- [27] G. Pfurtscheller and W. Klimesch, "Event-related synchronization and desynchronization of alpha and beta waves in a cognitive task," in *Induced rhythms in the brain*, ed: Springer, 1992, pp. 117-128.
- [28] C. Neuper, R. Scherer, M. Reiner, and G. Pfurtscheller, "Imagery of motor actions: Differential effects of kinesthetic and visual–motor mode of imagery in single-trial EEG," *Cognitive brain research*, vol. 25, pp. 668-677, 2005.
- [29] P. Márquez and R. Munoz, "Analysis and classification of electroencephalographic signals (EEG) to identify arm movements," in *Electrical Engineering, Computing Science and Automatic Control (CCE), 2013 10th International Conference on*, 2013, pp. 138-143.
- [30] E. Muñoz, "Adquisición, análisis y clasificación de señales electroencefalográficas (EEG) para identificar movimientos reales de extremidades superiores," Tesis de maestría, Dpto. de Ingeniería Eléctrica,

Centro de Investigación y de Estudios Avanzados del IPN, Ciudad de México, 2016.

- [31] M. H. Alomari, A. Samaha, and K. AlKamha, "Automated classification of L/R hand movement EEG signals using advanced feature extraction and machine learning," *Preface*, vol. 4, no. 6, 2013.
- [32] C. Brunner, R. Leeb, G. Müller-Putz, A. Schlögl, and G. Pfurtscheller, "BCI Competition 2008–Graz data set A," *Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces), Graz University of Technology*, pp. 136-142, 2008.
- [33] R. Leeb, C. Brunner, G. Müller-Putz, A. Schlögl, and G. Pfurtscheller, "BCI Competition 2008–Graz data set B," *Graz University of Technology, Austria*, 2008.
- [34] M. P. Mobarak, M. J. G. Salgado, R. M. Guerrero, and V. L. Dorr, "Transient state analysis of the multichannel EMG signal using Hjorth's parameters for identification of hand movements," in *International Multi-Conference on Computing in the Global Information Technology, ICCGI 2014*, 2014.
- [35] B. Obermaier, C. Guger, C. Neuper, and G. Pfurtscheller, "Hidden Markov models for online classification of single trial EEG data," *Pattern recognition letters*, vol. 22, pp. 1299-1309, 2001.
- [36] H. Lee and S. Choi, "PCA-based linear dynamical systems for multichannel EEG classification," in *Neural Information Processing, 2002. ICONIP'02. Proceedings of the 9th International Conference on*, 2002, pp. 745-749.

- [37] S.-H. Oh, Y.-R. Lee, and H.-N. Kim, "A novel EEG feature extraction method using Hjorth parameter," *International Journal of Electronics and Electrical Engineering*, vol. 2, pp. 106-110, 2014.
- [38] L. I. Smith, "A tutorial on principal components analysis," *Cornell University, USA*, vol. 51, p. 65, 2002.
- [39] N. J. Salkind, *Encyclopedia of measurement and statistics*. Thousand Oaks. California: Sage Publications, 2006, vol. 1, pp. 128-129.
- [40] J. Sleight, P. Pillai, and S. Mohan, "Classification of executed and imagined motor movement EEG signals," *Ann Arbor: University of Michigan*, pp. 1-10, 2009.
- [41] A. Khasnobish, S. Bhattacharyya, A. Konar, D. Tibarewala, and A. K. Nagar, "A Two-fold classification for composite decision about localized arm movement from EEG by SVM and QDA techniques," in *Neural Networks (IJCNN), The 2011 International Joint Conference on*, 2011, pp. 1344-1351.
- [42] R. Kohavi, "A study of cross-validation and bootstrap for accuracy estimation and model selection," in *Ijcai*, 1995, pp. 1137-1145.
- [43] M. J. Katz, "Fractals and the analysis of waveforms," *Computers in biology and medicine*, vol. 18, pp. 145-156, 1988.
- [44] A. Accardo, M. Affinito, M. Carrozzi, and F. Bouquet, "Use of the fractal dimension for the analysis of electroencephalographic time series," *Biological cybernetics*, vol. 77, pp. 339-350, 1997.