

01132
55



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

FACULTAD DE INGENIERÍA

“CARACTERIZACIÓN Y CLASIFICACIÓN DE
SEÑALES EEG USANDO HERRAMIENTAS DSP
PARA LA TOMA DE DECISIONES ASISTIDA POR
COMPUTADORA”

T E S I S

QUE PARA OBTENER EL TÍTULO DE:
INGENIERO EN COMPUTACIÓN

PRESENTA:

EDGAR ULISES LEDESMA ROJAS



DIRECTOR DE TESIS:
DR. ROGELIO ALCÁNTARA SILVA

A

CIUDAD UNIVERSITARIA

2003



Universidad Nacional
Autónoma de México

Dirección General de Bibliotecas de la UNAM

Biblioteca Central



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

PAGINACION

DISCONTINUA

**TESIS CON
FALLA DE
ORIGEN**

**UNIVERSIDAD NACIONAL
AUTONOMA DE MEXICO**

FACULTAD DE INGENIERIA

**“Caracterización y clasificación de señales
EEG usando herramientas DSP para la toma
de decisiones asistida por computadora ”**

Edgar Ulises Ledesma Rojas

**Director de Tesis: Dr. Rogelio Alcántara
Silva.**

Noviembre 2003.

Dedicatoria

A las personas más importantes en mi vida, mis padres: Magdalena Rojas y Luis Ledesma, que me han dado todo lo que un hijo puede esperar; amor, confianza y libertad. A la Ingeniera Ariana Moreno, por su apoyo, cariño y compañía incondicional.

Agradecimientos

Agradezco a todas aquellas personas que directa o indirectamente intervinieron en la realización de este trabajo.

Especialmente:

Al Doctor Rogelio Alcántara Silva, quien siempre creyó en mí y me brindó todo su apoyo y amistad.

A la Doctora Matilde Valencia, responsable del laboratorio de trastornos del sueño en la Facultad de Psicología de la UNAM y especialmente a la Doctora Rosa María Campos que me brindó su amistad y me hizo sentir parte de su equipo.

A la Facultad de Ingeniería y a todos mis maestros por formarme y hacer de mí una mejor persona.

Y finalmente a la Universidad Nacional Autónoma de México por ser mi segundo hogar y por la oportunidad de superación que representa.

Resumen

Con la caracterización y clasificación de señales de EEG podemos, por ejemplo, generar comandos de control o sistemas automáticos de análisis de sueño. Por lo anterior, el propósito de esta tesis fue caracterizar y clasificar la actividad EEG mediante tres herramientas del procesamiento digital de señales: función de autocorrelación, densidad espectral de potencia y espectrograma. Se tomó como primer caso de estudio la actividad EEG correspondiente a ojos abiertos y ojos cerrados y se propuso una arquitectura básica de procesamiento que soporta la idea de generar comandos de control a través de estos estados. Como ejemplo adicional, caracterizamos y clasificamos la actividad cerebral producida durante el sueño. Mediante el esquema de procesamiento con función de autocorrelación se obtuvo un 78 % de aciertos en la clasificación, mientras que con el esquema de PSD se obtuvo un 88 % de acierto en la clasificación, con lo que se mejoró en un 10 %; sin embargo, el costo computacional es mayor para el caso de la PSD que para la correlación. El espectrograma fue usado como herramienta complementaria a la PSD para observar el comportamiento frecuencial de la señal a lo largo del tiempo. La clasificación mediante esta herramienta se plantea como trabajo futuro.

Índice general

Glosario	XI
Introducción	1
1. Señales bioeléctricas	4
1.1. Introducción	4
1.2. Origen de las señales bioeléctricas	5
1.2.1. Ley de Fik	5
1.2.2. Potencial de reposo	7
1.2.3. Potencial de acción	7
1.3. Señales de EEG	8
1.3.1. Actividad Alfa	9
1.3.2. Actividad Beta	10
1.3.3. Actividad Theta	10
1.3.4. Actividad Delta	10
1.3.5. Ritmo μ	10
1.4. Potenciales Evocados	12
1.4.1. Potencial Evocado Visual (PEV)	12
1.4.2. Potencial Evocado Auditivo (PEA)	12
1.4.3. Potencial Evocado Somatosensorial (PES)	12
1.4.4. Potenciales Evocados Vestibulares PEVEST	12
1.5. Registro de ondas Cerebrales	13
1.6. Sistema de colocación de Electrodo 10 - 20	13
1.7. Montajes	15
1.8. Otras señales bioeléctricas	16
1.8.1. Señales EMG	17
1.8.2. Señales de ECG	17
1.8.3. Respiración	18

1.8.4. Señales OCG	19
1.9. Conclusiones	19
2. Hardware de Adquisición de Ondas cerebrales	21
2.1. Introducción	21
2.2. Elementos en la adquisición de señales de EEG	22
2.2.1. Transductor	23
2.2.2. Etapa de amplificación	24
2.2.3. Etapa de Filtrado	25
2.2.4. Conversion analógica digital	25
2.3. Conclusiones	26
3. Procesamiento digital de señales de EEG	27
3.1. Introducción	27
3.2. Características generales de una señal EEG	28
3.3. Análisis en el tiempo de una señal EEG	28
3.3.1. Análisis de cruces por cero	28
3.3.2. Análisis de autocorrelación	29
3.4. Análisis en el dominio de la frecuencia	29
3.4.1. Densidad Espectral de Potencia de la señal EEG	30
3.4.2. Periodograma de la señal EEG	30
3.4.3. Estimación de la densidad espectral de potencia de la señal de EEG mediante el modelo Autorregresivo (AR)	31
3.5. Conclusiones	37
4. Elementos para la clasificación de señales EEG	38
4.1. Introducción	38
4.2. Clasificación de patrones	39
4.3. Funciones de distancia	41
4.4. Algoritmo de clasificación	42
4.5. Conclusiones	44
5. Interfaces Hombre Máquina mediante señales EEG	45
5.1. Introducción	45
5.2. Modelo Funcional de una BCI	46
5.3. Taxonomía de las BCI	48
5.4. Clasificación de las BCI	50
5.5. Mecanismos Neurológicos comunmente utilizados en BCI	51

5.5.1.	Detección del potencial evocado P300	51
5.5.2.	Acondicionamiento del ritmo μ	52
5.5.3.	Detección de potenciales evocados visuales	52
5.5.4.	Detección de diferencias entre hemisferios laterales	53
5.6.	Conclusiones	53
6.	Implementación de una interface hombre máquina	54
6.1.	Introducción	54
6.2.	Diseño de nuestra Interface	55
6.2.1.	Taxonomía de nuestra interface	56
6.3.	Adquisición de las señales	57
6.4.	Preprocesamiento de la señal EEG	58
6.5.	Módulo para el procesamiento de señales EEG	59
6.5.1.	Extracción de características basada en correlación y potencia	59
6.5.2.	Extracción de características basada en FFT y PSD	61
6.5.3.	Extracción de características basada en el modelo AR	62
6.6.	Módulo de clasificación	65
6.7.	Simulaciones y pruebas	66
6.7.1.	Registro EEG con Ojos Abiertos. Ritmo Beta	66
6.7.2.	Registro EEG con Ojos cerrados. Ritmo Alfa	70
6.7.3.	Registro EEG de sueño.	73
6.8.	Resultados en la clasificación	81
6.9.	Conclusiones	82
	Conclusiones y Perspectivas	84
	Bibliografía	87
	Apéndices	90
A.	El Sueño	90
A.1.	Introducción	90
A.2.	Fases del sueño	91
A.2.1.	Fase 1	91
A.2.2.	Fase 2	91
A.2.3.	Fase 3	92
A.2.4.	Fase MOR	92

A.3. Hipnograma	93
A.4. Higiene de sueño	94
B. Código en MATLAB	95
B.1. Autocorrelación scsgada	95
B.2. myfft	95
B.3. Periodograma	96
B.4. Levinson Durbin	96
B.5. Respuesta en frecuencia	97
B.6. Distancia de Chebyshev	97
B.7. Distancia espectral RMS	98
B.8. Clasificador	98
B.9. artifact	99
B.10.limpia	100
B.11.EEG sintética	100
B.11.1. Señal Alfa	100
B.11.2. Señal Beta	101
B.11.3. Señal Teta	101
B.11.4. Señal Delta	101
C. Algoritmo de Levinson Durbin	102

Índice de figuras

1.1. Interpretación gráfica de la concentración molar en función de la distancia	6
1.2. Formas típicas de la actividad EEG [12]	9
1.3. Regiones del cráneo	11
1.4. Sistema internacional 10-20	14
1.5. Montaje monopolar	16
1.6. Montaje bipolar	16
1.7. Señal ECG típica,[12]	18
2.1. Elementos en la adquisición de señales EEG	22
2.2. Electrodo de superficie para el registro de EEG	23
3.1. Diagrama a bloques de un sistema asociado a un modelo AR	33
4.1. Esquema básico del reconocimiento de patrones	39
4.2. Entrenamiento Supervisado	41
6.1. Arquitectura propuesta de una BCI	55
6.2. Segmentación de la señal EEG	59
6.3. Extracción de características mediante autocorrelación y potencia	60
6.4. Diagrama de flujo para la extracción de características mediante correlación y potencia	61
6.5. Diagrama de flujo para la extracción de características mediante DFT y PSD	63
6.6. Diagrama a bloques para la obtención de los coeficientes a_i	63
6.7. Diagrama de flujo para la extracción de parámetros a_i	64

6.8. Señal temporal Beta	66
6.9. Función autocorrelación ritmo Beta	67
6.10. PSD ritmo Beta	68
6.11. Espectrograma ritmo Beta	69
6.12. Señal temporal Alfa	70
6.13. Función de autocorrelación ritmo Alfa	71
6.14. PSD del ritmo Alfa	72
6.15. Espectrograma ritmo Alfa	73
6.16. Registro temporal de sueño	74
6.17. Clases representativas	75
6.18. Espectrograma del registro de sueño original	76
6.19. Espectrograma del registro de sueño clasificado	77
6.20. Características temporales del ritmo Teta	78
6.21. Características frecuenciales del ritmo Teta	79
6.22. Características frecuenciales del ritmo Delta	80
6.23. Características frecuenciales del ritmo Delta	81
A.1. Ejemplo de hipnograma normal	93

Glosario

- a_i:** Coeficientes de la ecuación en diferencias de un sistema asociado a un modelo autoregresivo.
- Modelo AR:** Modelo Autoregresivo. Modelo basado en un sistema todo polo, [1].
- Modelo ARMA:** Modelo Autoregresivo de Promedios Móviles: Modelo basado en sistemas con polos y ceros, [1].
- BCI:** Del inglés *Brain Computer Interface*.
- DFT:** Del inglés *Discret Fourier Transform*. Transformada Discreta de Fourier. Herramienta del procesamiento digital de señales que transforma una secuencia de dominio temporal en otra de dominio frecuencial.
- DSP:** Del inglés *Digital Signal Processing*. Procesamiento Digital de Señales.
- ECG:** Electrocardiograma. Registro eléctrico de la actividad cardiaca.
- EEG:** Electroencefalografía. Registro de la actividad eléctrica del cerebro.
- EMG:** Electromiografía. Registro de la actividad eléctrica muscular.
- FFT:** Del inglés *Fast Fourier Transform*. Algoritmo que reduce el número de operaciones necesarias para calcular una DFT.
- Modelo MA:** Modelo de Promedios Móviles. Modelo basado en sistemas todo cero, [1].
- MOR:** Movimientos Oculares Rápidos. Nombre que recibe la etapa de sueño caracterizada por el movimiento rápido de ojos y por la aparición de imágenes oníricas comunmente llamadas sueños.

- OCG:** Oculografía. Registro eléctrico de la actividad ocular.
- P300:** Cambio en la actividad eléctrica cerebral que bajo ciertas condiciones se presenta 300 milisegundos después de un estímulo; [4].
- PEV:** Potencial Evocado Visual. Cambio en la actividad eléctrica cerebral que se presenta en respuesta a un estímulo visual,[12].
- PEA:** Potencial Evocado Auditivo. Cambio en la actividad eléctrica cerebral que se presenta en respuesta a un estímulo auditivo, [12].
- PES:** Potencial Evocado Somatosensorial Cambio en la actividad eléctrica cerebral que se presenta después de la estimulación de los nervios sensoriales periféricos,[12].
- PEVEST:** Potencial Evocado Vestibular. Cambio en la actividad eléctrica cerebral que se presenta en respuesta a una aceleración repentina de la cabeza, por ejemplo un giro brusco,[12].
- PSD:** Del inglés *Power Spectral Density*. Densidad espectral de potencia. Representa la distribución de la potencia de una señal en función de la frecuencia.
- Potencial Evocado:** Actividad eléctrica cerebral provocada por estimulación sensorial.
- R_x :** Función de autocorrelación. Algunos autores como Proakis[22] la denotan como R_{xx}
- STFT:** Del inglés *Short Time Fourier Transform*. Herramienta DSP basada en la Transformada de Fourier que obtiene el contenido frecuencial de una señal a lo largo del tiempo.

Introducción

Hoy en día existen muchos investigadores en todo el mundo dedicados a la tarea de crear interfaces que sirvan de canal de comunicación entre los individuos y el medio ambiente sin la intervención de músculo alguno; sin embargo, hasta la fecha, las interfaces con las que se obtienen mejores resultados siguen siendo aquéllas controladas por músculos, voz y señales oculares.

Explorar alternativas en el campo del procesamiento digital de señales (DSP) para el mejoramiento de los resultados de interfaces no musculares, específicamente aquéllas en las que intervienen las señales EEG, y su implementación posterior, puede abrir el camino a múltiples aplicaciones; por ejemplo aquéllas relacionadas con incapacidad psicomotora, dispositivos de entrada para computadoras, monitoreo de estado de vigilia para automovilistas y transportistas, registro de sueño a través de hipnogramas, control de anestesia, etc.

La idea de crear interfaces controladas con señales de EEG (BCIs), no es nueva; las primeras investigaciones fueron realizadas por la Fuerza Aérea de los Estados Unidos en la década de los 70's,[16], y aunque por cuestiones tecnológicas y de presupuesto fueron abandonadas, la idea de crear BCIs no fué desechada del todo.

La posibilidad de poder controlar un avión mediante el pensamiento, no sólo inspiró a escritores de ciencia ficción como Craig Thomas en su novela "Firefox", sino también a la comunidad científica. Actualmente estamos lejos de poder controlar un avión, sin embargo, las investigaciones recientes se centran en aplicaciones de control de cursores de computadora,[28], joisticks,[18], sistemas de comunicación simples, como la selección de letras de un teclado,[25]; y finalmente el control de neuro-prótesis,[9].

En la presente tesis usamos herramientas PSD para la obtención de características útiles en la clasificación y caracterización de señales electroencefalográficas (EEG) a fin de obtener un esquema de procesamiento y clasificación con miras a la implantación de una interfaz hombre máquina controlada con señales cerebrales.

Tomando como ejemplo la actividad cerebral registrada en dos estados: Ojos abiertos y Ojos cerrados; nuestra tarea se centra principalmente en la caracterización y clasificación de las señales EEG representativas de dichos estados. Para ello, proponemos 3 esquemas de procesamiento usando las siguientes herramientas:

1. Funciones de autocorrelación y potencia de la señal
2. técnicas frecuenciales basadas en la transformada de Fourier discreta (DFT)
3. Modelando la señal EEG como un proceso autorregresivo

La parte referente a la clasificación de las señales EEG, se realiza mediante la asignación de clases basadas en funciones de distancia. En este trabajo utilizamos 2 de ellas:

- Distancia de Chebyshev
- Distancia espectral RMS

Con este trabajo queremos mostrar que al ser capaces de caracterizar y clasificar un cierto tipo de actividad cerebral, estamos en posibilidades de asignarle una tarea; claro está que entre más señales podamos detectar, mayor número de tareas podemos asignar, y la interacción con el medio a través de una interfaz de este tipo se hace más grande.

Para alcanzar nuestro objetivo, dividimos el presente trabajo en 6 capítulos:

Capítulo 1. Presenta de manera general una introducción a los fenómenos físicos y químicos que dan origen a los distintos potenciales biológicos, enfatizando aquellos que caracterizan la actividad eléctrica del cerebro. Se abordan las distintas técnicas de registro de la actividad eléctrica cerebral, en especial la técnica de encefalografía.

Capítulo 2. Describe los elementos básicos de un sistema de adquisición de señales EEG y la problemática que hay que resolver cuando se trabaja con éste tipo señales altamente susceptibles al ruido.

Capítulo 3. Dentro de las técnicas empleadas en el procesamiento digital se encuentra la caracterización de las señales en el dominio del tiempo, la frecuencia y su modelado. Este hace referencia a los conceptos útiles para el procesamiento digital de una señal EEG y se describen algunos métodos ampliamente utilizados.

Capítulo 4. Se introduce la idea de la clasificación de patrones y se revisa el algoritmo que implementaremos para nuestro clasificador.

Capítulo 5. En este capítulo se revisan algunos de los trabajos más importantes en el desarrollo de sistemas BCI que sirvieron de inspiración para desarrollar un sistema propio.

Capítulo 6. Propone una interfaz cerebral adecuando el modelo descrito por Mason [17] para un ejemplo de generación de comandos mediante la actividad EEG correspondiente al caso ojos abiertos y ojos cerrados. Adicionalmente, y siguiendo el mismo modelo, se toma como ejemplo la caracterización de registro de sueño y se presentan y comentan los resultados obtenidos.

Capítulo 1

Señales bioeléctricas

1.1. Introducción

La actividad eléctrica generada por organismos vivos da origen a lo que conocemos como señales bioeléctricas. Por medio de las señales bioeléctricas es posible determinar la fisiología de las estructuras biológicas. Las señales bioeléctricas no solo nos ayudan a comprender el funcionamiento, sino también, a determinar distintos padecimientos en los seres vivos.

Por otro lado, el cerebro,[12], constituye el órgano principal de los seres humanos, en él se encierran grandes secretos en lo que respecta a percepción, sensación, procesos motrices, cognoscitivos, sueño, etc. por lo que resulta de particular importancia su estudio. Hoy en día existen numerosas técnicas empleadas en el estudio de éste órgano tan importante, aunque dichas técnicas actualmente se basan en la obtención de imágenes, en el registro de su actividad eléctrica, y en técnicas de índole psicológicas,[24].

A continuación se presentan los fenómenos físicos y químicos que dan origen a los distintos potenciales biológicos, sin embargo se hace énfasis en aquellos que caracterizan la actividad eléctrica del cerebro; por otro lado se abordan los distintas formas de registrar la actividad eléctrica cerebral principalmente en lo que respecta a la encefalografía.

1.2. Origen de las señales bioeléctricas

El estudio de los potenciales biológicos data desde 1786 con el trabajo de Luigi Galvani.[2]

Las señales bioeléctricas son el resultado de los *potenciales de reposo* y los *potenciales de acción*. Las células son estructuras rodeadas por una capa permeable llamada membrana celular. Dentro de la membrana celular se originan numerosas y complejas reacciones químicas. La característica de permeabilidad y la distinta concentración de iones (mayor concentración al interior), generalmente de potasio, sodio y cloro, dan lugar a la aparición de un potencial eléctrico del orden de los -90mv (el potencial exterior se mide respecto al potencial interior de la membrana celular). La ley que establece este fenómeno iónico (además del campo eléctrico) es la *ley para la difusión de Fick* .[12].

1.2.1. Ley de Fick

La ley de Fick establece que si existe una alta concentración de partículas con movimiento libre en una región, éstas fluirán en una dirección para equilibrar la concentración(C) a través de la región. Matemáticamente la ley de Fick se expresa como: [2]

$$J = -D \frac{d[C]}{dx} \left[\frac{\text{Amperes}}{\text{metro}^2} \right] \quad (1.1)$$

Donde:

J= Fuerza de difusión.

D = Constante de difusión

x = Posición

C = Concentración de iones en función de la distancia. Ver figura(1.1)

Además de la fuerza de difusión existe otra fuerza, debida al campo eléctrico, que actúa sobre los iones. Como consecuencia de las fuerzas de atracción y repulsión que las partículas con carga experimentan dentro de un campo

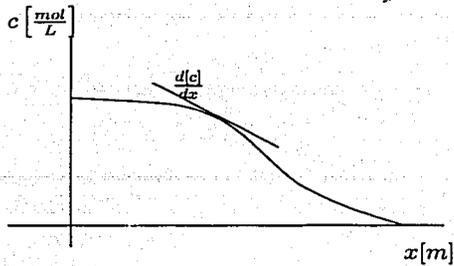


Figura 1.1: Interpretación gráfica de la concentración molar en función de la distancia

eléctrico, aparece una corriente llamada corriente de desplazamiento. La corriente de desplazamiento se expresa como:

$$J_d = -\mu Z C \frac{dV}{dx} \quad (1.2)$$

Donde:

$\frac{dV}{dx}$ = Campo eléctrico $\left(\frac{\text{Volt}}{\text{metro}} \right)$

Z = valencia de los iones

C = Concentración molar $\left(\frac{\text{mol}}{l} \right)$

μ = Constante de movilidad de cada ión $\left(\frac{l \cdot A}{\text{Volt} \cdot \text{metro} \cdot \text{mol}} \right)$

La constante de movilidad μ , se refiere a la densidad de corriente debido al desplazamiento de partículas. La constante de movilidad μ y la constante de densidad o difusión D se relacionan por medio de la Relación de Einstein:

$$\frac{D}{\mu} = \frac{k \cdot T}{q} \quad (1.3)$$

Donde:

k = Constante de Boltzmann

q = es la carga

T = temperatura absoluta

1.2.2. Potencial de reposo

En equilibrio, el cual es la condición de una membrana celular en reposo, la densidad de corriente total para cualquier ión debe ser cero. La ecuación de Nernst[2] expresa lo anterior como:

$$V_m = -\frac{kT}{q} \ln \left(\frac{C_i}{C_e} \right) \quad (1.4)$$

Donde:

La Ecuación de Nernst puede ser usada para encontrar el potencial de equilibrio para cualquier ión permeable, cuyas concentraciones intracelulares, C_i , y extracelulares, C_e , son conocidas. Este potencial de equilibrio se conoce como *potencial de reposo*, V_m . Cuando la membrana celular presenta un potencial de reposo, se dice que la membrana está polarizada.

1.2.3. Potencial de acción

El potencial de reposo puede ser alterado por estímulos físicos o químicos. Cuando el potencial varía de forma que se hace más negativo, se dice que la membrana está *hiperpolarizada*; mientras que si varía de manera que se vuelve más positivo, se dice que la membrana se ha *despolarizado*. [2]

Si la célula se despolariza cerca de un 20% se carga positivamente por un instante y luego regresa a su estado de reposo. Este cambio se denomina potencial de acción. Sin embargo, existe un período en el que es imposible volver a inducir un potencial de acción en la célula, éste periodo se conoce como periodo refractario. El valor del periodo refractario nos da la máxima frecuencia de estimulación, la cual indica el periodo en que se puede inducir un potencial de acción en la célula. Para la mayoría de las células del cuerpo humano, la frecuencia de estimulación es de 2 a 3 milisegundos, sin embargo, existen células como por ejemplo las cardiacas y las musculares que su frecuencia de estimulación es más lenta y puede durar desde los 0.15 hasta los 0.3 segundos. [2]

1.3. Señales de EEG

Las señales de EEG son señales obtenidas mediante registros eléctricos de la superficie del encéfalo; las cuales revelan la actividad celular en el cerebro de un sujeto; su origen se debe a las descargas eléctricas sincrónicas de millones de neuronas principalmente relacionadas con las corrientes de sinapsis dendríticas ¹. A estas fluctuaciones eléctricas se les conoce como ondas cerebrales.

La actividad eléctrica del cerebro fue descubierta por Hans Berger a finales de los años 20; él fue también el primero en clasificar las señales EEG de acuerdo a su frecuencia y amplitud. Con base a los estudios de Berger; Loomis, Harvey y Hobart (1937 y 1938) trabajaron sobre observaciones en el cambio de ritmo de la actividad eléctrica cerebral durante el transcurso del sueño.[24]

Hoy sabemos que la intensidad de las ondas cerebrales depende de la cantidad de neuronas que intervienen en el proceso de descarga, mientras que la periodicidad (de las ondas) está dada por el nivel de excitación con que se encuentre cada neurona. Esto enfatiza el porque las ondas cerebrales de un sujeto son mas lentas durante el sueño que durante el período de vigilia.

La actividad EEG varía de acuerdo a la edad y al estado de los individuos. Los niños muestran cambios sistemáticos en los estados de vigilia y sueño de acuerdo a su edad; estos cambios se hacen menos complejos hasta alcanzar la adultez; en tanto los adultos presentan una complejidad menor en su actividad cerebral en ambos estados.

La mayor parte del tiempo las ondas cerebrales presentan patrones irregulares, sin embargo siguiendo la clasificación de Berger, las señales pueden ser fundamentalmente de cuatro tipos:

¹La corriente de sinapsis dendrítica es aquella que aparece cuando las neuronas se conectan entre ellas,[12].

- Ondas Alfa
- Ondas Beta
- Ondas Theta
- Ondas Delta

La figura(1.3) muestra las formas características de los distintos ritmos de EEG

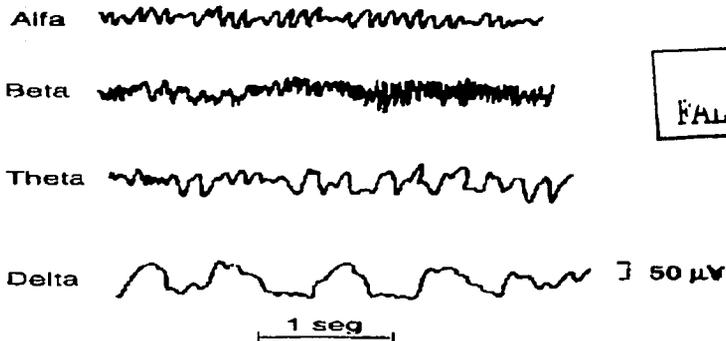


Figura 1.2: Formas típicas de la actividad EEG [12]

No obstante que la actividad cerebral varía de individuo a individuo, es posible señalar algunas de las características más importantes de cada tipo. De acuerdo con [10], se tiene:

1.3.1. Actividad Alfa

El ritmo Alfa predomina en la región occipital(figura 1.3); es fácilmente reconocido en individuos de 20 - 60 años cuando éstos mantienen los ojos cerrados.

El ritmo Alfa posee una frecuencia que va de los 8 Hz a los 12 Hz y su voltaje se encuentra en el rango de los $20\mu V$ - $60\mu V$.

Otra característica del ritmo Alfa es que éste puede ser fácilmente atenuado por estímulos visuales y también por aumento en la atención o concentración.

1.3.2. Actividad Beta

La actividad Beta se caracteriza por tener una frecuencia mayor de 13 Hz; su voltaje típico está dentro de los $5\mu V$. El ritmo Beta predomina en las regiones centrales y frontales (figura 1.3) del encéfalo. Este ritmo se presenta durante la vigilia y también durante ciertos períodos del sueño. El ritmo Beta puede ser bloqueado mediante la actividad motora o la estimulación táctil.

1.3.3. Actividad Theta

La actividad theta es una actividad cuyas frecuencias van de los 4 Hz a los 7 Hz y predomina en las áreas central, temporal y parietal (figura 1.3); sin embargo, es más prominente en el lado izquierdo que en el derecho.

1.3.4. Actividad Delta

Las ondas Delta poseen frecuencias inferiores a 3,5 Hz y una gran amplitud, generalmente mayor a los $100\mu V$. En sujetos sanos se presentan durante el sueño profundo no MOR y en la infancia; también es común encontrar este tipo de actividad en individuos que padecen enfermedades orgánicas cerebrales graves. La actividad Delta es predominante en todas las regiones del encéfalo (figura 1.3).

1.3.5. Ritmo μ

El ritmo μ , o actividad rolándica, se encuentra típicamente a una frecuencia de 10 Hz y se localiza en el área precentral y postcentral. El ritmo μ es bloqueado por movimientos voluntarios, involuntarios o reflexivos. El efecto de bloqueo aparece antes del comienzo de la contracción muscular en el caso de movimientos voluntarios o involuntarios; y con imaginar el movimiento, cuando se trata de un movimiento reflexivo.

Cuadro 1.1: Resumen de características de la actividad EEG

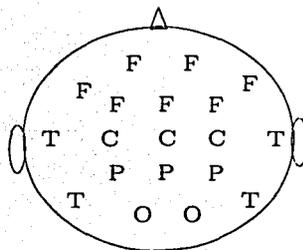
Señal	Zona Craneal	Voltaje (μV)	Frecuencia (Hz)	Característica
Alfa	Occipital	20	8-12	Relajación
Beta	Central	5	13-30	Concentración
Delta	Todas	75-150	0.5-3.5	Sueño profundo
Teta	Temporal	50-75	4-7	Sueño etapa 3
μ	Central	7-10	10	Imaginación movimiento

Frontal (F)

Central (C)

Parietal (P)

Occipital (O)



TESIS CON FALLA DE ORIGEN

Figura 1.3: Regiones del cráneo

1.4. Potenciales Evocados

Los potenciales evocados son variaciones del potencial de la señal EEG que se producen como respuesta a un estímulo sensorial. Los potenciales evocados más conocidos se describen en la siguiente sección.[19]

1.4.1. Potencial Evocado Visual (PEV)

La respuesta de este potencial se verifica en la zona occipital y puede ser desencadenada por medio de estímulos visuales dentro de la totalidad del campo visual, o sólo en ciertas regiones. Los estímulos más usados son el destello de un flash, y la aparición de barras multicolores dentro del campo visual.

1.4.2. Potencial Evocado Auditivo (PEA)

Este potencial aparece en personas normales de 10 a 15 milisegundos después de un estímulo auditivo. La forma de los PEAs está bien definida. Se componen de tres etapas, la primera, conocida como potencial evocado de latencia corta o potencial auditivo de tallo cerebral; la segunda, llamada respuesta auditiva de latencia media; y por último, la respuesta tardía o de latencia larga. Las etapas de los PEAs se asocian a la estimulación que se produce en la trayectoria auditiva.

1.4.3. Potencial Evocado Somatosensorial (PES)

Este potencial aparece después de la estimulación de los nervios sensoriales periféricos. Su respuesta se aprecia mejor en la zona frontoparietal. Los estímulos comúnmente usados para desencadenar los PES son: eléctricos, térmicos y táctiles; siendo los primeros los de uso más difundido por su mejor control.

1.4.4. Potenciales Evocados Vestibulares PEVEST

Este tipo de potencial evocado apenas se ha empezado a investigar y se sabe que los PEVEST aparecen como respuesta a la aceleración que sufre la cabeza de un individuo cuando se le hace girar abruptamente.

1.5. Registro de ondas Cerebrales

El registro de señales EEG puede obtenerse de distintas formas: de forma superficial a través del cuero cabelludo; desde la base del cráneo; cerebro expuesto; o desde zonas profundas del cerebro.

Existen electrodos especiales para cada técnica,[10]:

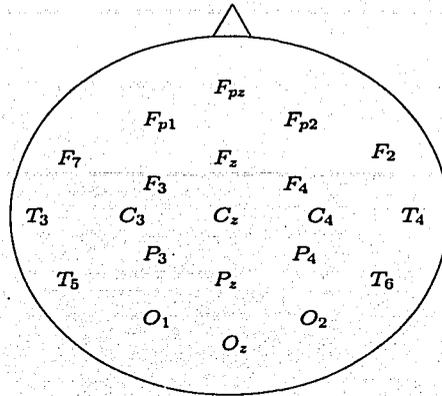
- Electrodoes superficiales: se colocan sobre el cuero cabelludo.
- Electrodoes basales: aquellos que se colocan sobre el hueso del cráneo.
- Electrodoes quirúrgicos: electrodoes que para su colocación se requieren técnicas quirúrgicas especializadas; pueden ser de dos tipos: corticales, colocados sobre la superficie del cerebro; o intracerebrales, colocados en zonas profundas del cerebro.

De acuerdo con la forma empleada para la obtención de las señales EEG, el registro toma diferentes nombres,[10]:

- Electroencefalograma (EEG): se llama así al registro obtenido sin el empleo de técnicas quirúrgicas
- Electrocorticograma (ECoG): es el registro obtenido en la corteza cerebral
- Electroencefalograma (E-EEG): cuando se registra desde zonas intracerebrales

1.6. Sistema de colocación de Electrodoes 10 - 20

Dada la existencia de variados sistemas de registro, tales como el Illinois, el Montreal, el Aird, el Cohn, el Lennox, el Merlis, el Oastaut, el Schwab, el Marshall, entre muchos otros, que hacían difícil el intercambio de resultados entre investigadores del fenómeno EEG, se hizo imperativa la necesidad de la estandarización del método de colocación de electrodoes para la obtención



TESIS CON
FALLA DE ORIGEN

Figura 1.4: Sistema internacional 10-20

de dichas señales,[24].

En 1957 se publica en "Report of the committee on methods of clinical examination in Encephalography" el estándar de colocación de electrodos para encefalografía denominado sistema 10 - 20, el cual es mundialmente usado,[24].

Tres de las ventajas más relevantes que proporciona el sistema de colocación 10 - 20 son las siguientes:

- El sistema de colocación 10 -20 crea un método de identificación para las distintas ubicaciones de los electrodos, el cual es usado mundialmente.
- La ubicación de los electrodos permite la medición exacta de voltajes sin importar el tamaño y forma del cráneo.
- Los resultados obtenidos con el uso del sistema 10 - 20 son exactamente los mismos sin importar el lugar o el equipo que se use.

En el sistema 10 - 20, cada electrodo tiene una abreviación de acuerdo a la zona del cerebro donde se coloque:

Cuadro 1.2: Abreviaturas de los electrodos de acuerdo a la región craneal

Abreviaturas	Región
C	Central
F	Frontal
O	Occipital
T	Temporal
P	Parietal
A	Auricular

La colocación de los electrodos se determina a partir de cuatro puntos anatómicos: el inión, el nasión, el preauricular derecho y el preauricular izquierdo,[15].

Cada electrodo está numerado; la numeración par corresponde a los electrodos del hemisferio derecho, mientras que la numeración impar corresponde a los ubicados en el hemisferio izquierdo.

1.7. Montajes

Un montaje es un conjunto de electrodos colocados sobre la superficie del cuero cabelludo en posiciones precisas determinadas por el sistema de colocación 10 - 20. Cada electrodo es un punto de registro. Pueden existir registros *monopolares* o *bipolares*.

Un registro básico de una señal electroencefalográfica se hace mediante dos electrodos; un electrodo recibe el nombre de *electrodo activo*, mientras que el otro se denomina *electrodo de referencia*.

Cuando se hace un registro monopolar, las señales se toman de manera independiente una de otras por medio de los electrodos activos; en tanto, teóricamente, los electrodos de referencia deben de estar situados en un punto

de potencial cero; sin embargo en la práctica resulta imposible tener un punto exacto de potencial cero y se toman potenciales de referencia aproximados como el lóbulo de la oreja, el mentón o el mastoideos.

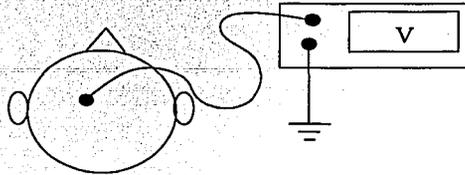


Figura 1.5: Montaje monopolar

Los registros bipolares se hacen tomando la diferencia de potencial que existe entre una pareja de electrodos activos. En un registro bipolar, el electrodo de referencia se convierte en un electrodo activo.

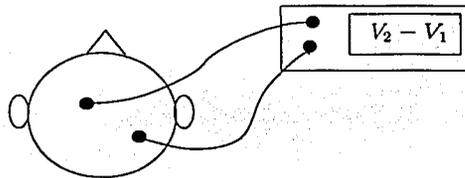


Figura 1.6: Montaje bipolar

TESIS CON
FALLA DE ORIGEN

1.8. Otras señales bioeléctricas

Un caso particular para el análisis de las ondas de electroencefalografía es el referente al estudio del sueño a través de sus diferentes ritmos, sin embargo, los investigadores del sueño suelen ayudarse de otras señales bioeléctricas además de las obtenidas por el método de la encefalografía. Ejemplo de estas señales son las señales de electromiografía (EMG), electrocardiografía

(ECG), oximetría, el flujo respiratorio y la electrooculografía (OCG).

Con todas las señales anteriores, los expertos en el área de sueño, pueden establecer una clasificación más precisa al correlacionar dichas señales con las de la electroencefalografía.

1.8.1. Señales EMG

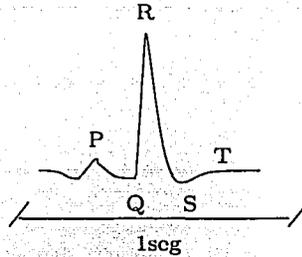
Las señales obtenidas por un electromiograma son generadas por la actividad eléctrica de las ramificaciones nerviosas en la musculatura. Cuando queremos mover algún músculo de nuestro cuerpo, el cerebro envía impulsos eléctricos hacia los músculos a través de los nervios. La frecuencia de las señales EMG son del orden de 500Hz.

1.8.2. Señales de ECG

Un electrocardiograma es el registro de las señales eléctricas que produce el corazón al latir. Generalmente, el electrocardiograma de diagnóstico se obtiene a partir de 12 o a veces 15 electrodos dispuestos a lo largo del tórax, brazos y piernas del paciente; sin embargo, en registros polisomnográficos, empleados principalmente en el estudio del sueño, el número de electrodos se reduce de 3 a 5 por tratarse de un estudio de control.

Un electrocardiograma normal está formado por una onda P, un complejo QRS, que a su vez contiene generalmente una onda Q, una R y una S; y finalmente por una onda T,[12].

1. *Onda P*: la onda P se relaciona con la despolarización de las aurículas. Su duración es menor a los 100ms.
2. *Intervalo PR*: es el periodo de inactividad eléctrica correspondiente al retraso fisiológico que sufre el estímulo en el nodo atrioventricular. Su duración debe estar comprendida entre los 120 y los 200ms.



TESIS CON
 FALLA DE ORIGEN

Figura 1.7: Señal ECG típica,[12]

3. *Complejo QRS*: representa la despolarización de ambos ventrículos. Su duración debe estar comprendida entre los 80 y 100ms.
4. *Segmento ST*: desde el final del QRS hasta el inicio de la onda T.
5. *Onda T*: Corresponde a la repolarización ventricular, apareciendo al final del segmento ST.
6. *Intervalo QT*: comprende desde el inicio del QRS hasta el final de la onda T y representa la despolarización y repolarización ventricular. Su duración estará comprendida entre los 320 y 400ms

1.8.3. Respiración

Aunque la respiración no es propiamente una señal de tipo eléctrico, sí constituye una variable importante a tomar en cuenta dentro de ciertos análisis médicos, sobre todo en aquellos que se refieren a trastornos neurológicos, cardíacos y del sueño. El instrumento encargado de hacer las mediciones correspondientes a la respiración recibe el nombre de neumógrafo, el cual se encarga de registrar el flujo aéreo nasal y la concentración de oxígeno en sangre.

1.8.4. Señales OCG

Las señales de electro-oculografía, son aquellas que conforman el registro eléctrico del movimiento ocular de un individuo. Principalmente éste estudio se emplea para la detección de problemas en el control y movimiento ocular.

La electrooculografía se realiza de manera general con 5 electrodos dispuestos alrededor de los ojos de manera tal que permitan el registro de la actividad motora en dirección vertical y horizontal.

Las señales registradas son señales de origen muscular, por lo que sus características de amplitud y frecuencia son similares.

En registros polisomnográficos dedicados al estudio de sueño, la electro-oculografía se emplea para registrar el movimiento ocular de un individuo mientras duerme con el fin de correlacionar la actividad ocular con las distintas fases del sueño.

1.9. Conclusiones

Las señales bioeléctricas tienen su origen en dos tipos de potenciales celulares: los primeros, conocidos como potenciales de reposo, que son aquellos que estando la célula en reposo se presentan por la diferencia de concentración de iones entre el interior y el exterior de la membrana celular; y los segundos llamados potenciales de acción, que se refieren a los potenciales generados cuando la célula recibe un estímulo.

Un tipo particular de señal bioeléctrica lo constituye el grupo de señales cerebrales, las cuales se clasifican, entre otras propiedades, de acuerdo a sus amplitudes y frecuencia en:

- Alfa
- Beta
- Teta
- Delta

Hay ocasiones, en las que la actividad eléctrica del cerebro se ve perturbada por estímulos sensoriales, estas variaciones se conocen como potenciales evocados. Aunque existen patrones definidos en las formas de onda resultado de un potencial evocado, éstos pueden variar dependiendo de características inherentes a la persona, como la edad, la capacidad sensorial, la atención, etc; y de circunstancias externas, como la magnitud del estímulo, la duración, el medio de desarrollo, etc.

Para registrar las distintas señales del cerebro se utilizan diversas técnicas, sin embargo, la electroencefalografía resulta ser la más adecuada para el estudio de éstas señales por ser un método simple, no invasivo y que no requiere de procedimientos quirúrgicos como otros; con la salvedad de que para que los registros de encefalografía sean interpretados adecuadamente en todo el mundo, éstos deberán de seguir la norma de colocación de electrodos 10 - 20 establecida por el "committee on methods of clinical examination in Encephalography",[24].

Capítulo 2

Hardware de Adquisición de Ondas cerebrales

2.1. Introducción

Un registro de EEG implica la medición o sensado, la amplificación, el filtrado, la digitalización y el procesamiento de las diferentes fluctuaciones eléctricas del cerebro como función del tiempo.

La importancia de contar con un buen hardware de adquisición de ondas cerebrales radica en la reducción en el costo computacional utilizado en el procesamiento y análisis de las señales EEG.

Los especialistas en neurología y otros, de áreas afines, encuentran gran utilidad en la electroencefalografía como herramienta de diagnóstico para problemas físicos que se manifiestan en la alteración de las ondas cerebrales.

El diseño y construcción de un equipo de adquisición de ondas cerebrales es complejo, sobre todo porque el problema implica el manejar señales de muy bajo voltaje y enorme susceptibilidad al ruido; además de que las señales de origen encefálico existen en un rango de frecuencias bajas que es necesario identificar.

Durante el desarrollo del capítulo se describen los elementos de un sistema de adquisición de ondas cerebrales.

2.2. Elementos en la adquisición de señales de EEG

De manera general, un sistema de adquisición de datos es un conjunto de dispositivos que nos permiten tomar señales de nuestro entorno y convertirlas en información útil para su posterior análisis.[21]. Por lo regular, dichos sistemas se encuentran constituidos al menos con los siguientes elementos:

- Sensor/Transductor
- Amplificación de señal
- Filtrado
- Conversión analógica Digital

TESIS CON
FALLA DE ORIGEN

Los electroencefalógrafos son sistemas de adquisición de datos especialmente diseñados para el registro de señales cerebrales tomadas directamente de la superficie del cráneo.[10].

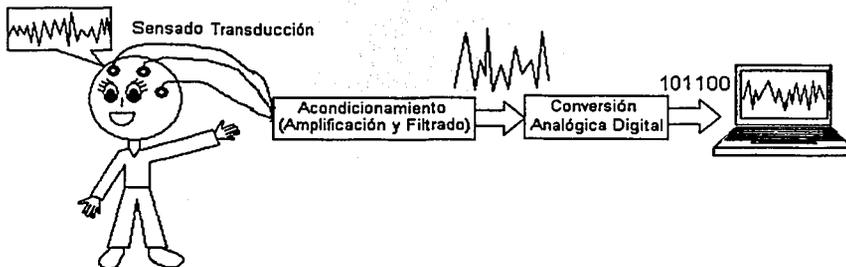


Figura 2.1: Elementos en la adquisición de señales EEG

2.2.1. Transductor

Un transductor es un elemento que convierte una magnitud física en otra, generalmente en tensión o corriente, salvo que nuestra entrada ya sea una señal eléctrica. Una característica importante de un transductor es que éste deberá tomar poca energía del sistema a medir, para que no cause errores en la medición.[21]

Los transductores usados para la electroencefalografía, son normalmente conocidos como electrodos. ver figura(2.2). Dado que un registro de EEG se toma a partir de métodos no quirúrgicos, los electrodos usados para el registro de la actividad cerebral son los llamados electrodos de superficie, los cuales consisten de una superficie de metal que se junta con una solución electrolítica (generalmente gel o pasta) formando de este modo un acoplamiento capacitivo con el paciente.[2]



TESIS CON
FALLA DE ORIGEN

Figura 2.2: Electrodo de superficie para el registro de EEG

Cuando introducimos un metal en una sustancia electrolítica, se atraen ciertos tipos de iones, ya sea cationes o aniones; por lo que queda eléctricamente cargado. Los iones de carga opuesta son entonces atraídos formándose otra capa con carga opuesta a la primera, estos fenómenos forman una doble capa de carga en la superficie del metal estableciéndose de esta manera un equilibrio.[2]

Debido a la unión del electrodo (metal) con una solución conductora (pasta o gel electrolítico), la carga eléctrica producida por los iones de la solución que viajan hacia el metal, y la producida por los iones de metal que viajan hacia la solución, dan origen a un potencial en el electrodo conocido como *potencial de media celda*. La magnitud de este potencial depende de la concentración y composición de la sustancia electrolítica, del tipo de metal con

que se fabrique el electrodo y de la temperatura.[2]. El valor de este potencial va de los microvolts hasta unos cuantos volts; un valor aceptable para un registro de EEG es de $\pm 0.3\mu\text{V}$, [20].

Resulta difícil conocer el valor del potencial de media celda, sin embargo podemos conocer el valor del voltaje que cruza a través del electrodo por medio de otro electrodo, lo que quiere decir que podemos registrar la diferencia de potencial entre dicho par de electrodos.

2.2.2. Etapa de amplificación

Uno de los principales problemas que se deben solucionar para el registro de señales de EEG es la atenuación que estas señales sufren desde el punto donde se originan hasta llegar a la entrada de la etapa amplificadora del electroencefalógrafo. En general, en individuos normales, la magnitud de dichas señales va del orden de los $10\mu\text{V}$ hasta los $100\mu\text{V}$, [20]. Sin embargo, estas amplitudes resultan insignificantes para los convertidores analógico digitales utilizados en la etapa siguiente. Con el fin de aumentar la amplitud de las señales, se utilizan los circuitos de amplificación.

Amplificar una señal implica relacionar su valor no amplificado con aquel ya amplificado mediante una constante de amplificación. El valor de esta constante lo determina el nivel de voltaje máximo y mínimo en los que haremos funcionar al sistema; específicamente, los valores que determinan la magnitud de la amplificación son los voltajes máximos y mínimos que nuestro convertidor analógico digital admite,[21]. La manera más simple de obtener la relación existente entre los valores máximos y mínimos admisibles por un sistema es por medio de una relación lineal.[7]

Para la amplificación de las señales se utilizan dispositivos electrónicos llamados amplificadores operacionales. Son muy importantes las características de los amplificadores utilizados en EEG, sobre todo aquellas que se refieren a sus entradas, ganancia y ancho de banda; pues es aquí donde se lleva a cabo la medición de los potenciales eléctricos. Los amplificadores operacionales utilizados en equipos de cefalografía son conocidos como amplificadores de instrumentación,[7], los cuales son dispositivos muy sensibles capaces de proporcionar altas ganancias y gran inmunidad al ruido. La eficacia de estos amplificadores reside en su enorme capacidad de medir señales muy pequeñas,

del orden de microvolts o pocos milivolts en presencia de grandes señales de ruido provenientes de distintas fuentes.

2.2.3. Etapa de Filtrado

No sólo basta con corregir las discrepancias en los niveles de voltaje; hace falta corregir también los problemas causados por señales indeseables mejor conocidas como ruido. Los dispositivos con que eliminamos el ruido se conocen como filtros, los cuales sólo dejan pasar las señales de nuestro interés y suprimen las que no lo son.

En particular, los sistemas de encefalografía son altamente vulnerables al ruido. El ruido puede provenir de distintas fuentes,[2], las cuales pueden ser atribuibles al propio sistema, en cuyo caso la solución será un nuevo diseño; o fuentes de ruido externas, como una mala aplicación de los electrodos en la superficie del cuero cabelludo, la transpiración del paciente o hasta la fuente más común y muchas veces insospechada: la alimentación eléctrica.

Cual fuere la fuente de ruido, el efecto que produce en el sistema siempre es negativo. El filtrado tiene como propósito el eliminar tales efectos en nuestro sistema de adquisición. Para este propósito, existen distintas familias y tipos de filtros,[7]; según la familia y tipo que se escoja, la complejidad de esta etapa será diferente, así como sus métodos de diseño.

Los sistemas especializados de electroencefalografía cuentan con bancos de filtros tipo paso bajas, paso banda, paso altas y supresor de banda; todos ellos sintonizables en los rangos de frecuencias Alfa, Beta, theta, y Delta,[20]. Por otra parte también cuentan con una etapa que suprime el ruido producido por la línea de transmisión eléctrica,[20].

2.2.4. Conversion analógica digital

El dispositivo que une el mundo continuo de las señales físicas con el mundo discreto de los sistemas digitales se llama convertidor analógico digital,[7].

El convertidor analógico digital toma un voltaje de entrada y después de un cierto tiempo genera un código binario que representa el valor medido.

Dado que los valores de voltaje son continuos, es decir, que pueden tomar un número infinito de valores, los convertidores analógico digitales deben de ajustar su valor de salida al valor más cercano que les permita su resolución.

2.3. Conclusiones

Uno de los mayores problemas que deben afrontar los equipos de electroencefalografía es el ruido; los registros de EEG son altamente sensibles al ruido, por lo que contar con un buen equipo de adquisición de señales EEG resulta indispensable. Cuanto más limpias sean las señales que adquiramos, mayor será la eficiencia de los algoritmos de procesamiento y clasificación; esto implica que el hardware utilizado debe ser capaz de realizar un procesamiento básico de la señal. En la actualidad existen muchos sistemas de adquisición muy completos, los cuales realizan mediante hardware la mayor parte del procesamiento de la señal; sin embargo, la mayoría son caros y nada portátiles. Si pensamos en la implementación de interfaces hombre máquina, debemos tomar en consideración diferentes aspectos como el tamaño del equipo, el costo, la seguridad y un fácil manejo.

Capítulo 3

Procesamiento digital de señales de EEG

3.1. Introducción

El análisis de una señal puede llevarse a cabo con múltiples fines, por ejemplo: compresión, supresión de ruido, extracción de características en el dominio del tiempo y en el dominio de la frecuencia, detección, etc. Para ello, se aplican distintos métodos y algoritmos basados en las propiedades que una señal puede llegar a tener. Al tratamiento de las señales mediante estas herramientas se le conoce como procesamiento de señales.

El procesamiento de señales puede realizarse de manera analógica o bien digital. En años anteriores, en los que la capacidad de procesamiento, almacenamiento y memoria de las computadoras era muy reducida, la tarea del procesamiento de una señal se le encargaba a la parte del hardware de un sistema; hoy en día, con el gran avance tecnológico en el campo de las computadoras, el diseño de sistemas e implementación se han hecho más simples, y las tareas que antes sólo eran realizables mediante electrónica analógica, ahora pueden llevarse a cabo mediante arquitecturas basadas en software, lo que aumenta la eficiencia y reduce de manera sustancial los costos. Lo anterior ha enfatizado el desarrollo, estudio e implementación de técnicas de procesamiento que se ajusten a las propiedades de los cada vez más comunes sistemas digitales.

Dentro de las técnicas empleadas en el procesamiento digital se encuentra la caracterización de las señales en el dominio del tiempo, la frecuencia y el modelado.

En este capítulo nos referiremos a los conceptos útiles para el procesamiento digital de una señal EEG y mostraremos algunos métodos ampliamente utilizados.

3.2. Características generales de una señal EEG

Bajo la teoría de señales, las señales de EEG se clasifican como señales aleatorias a valores reales y continuas en el tiempo. Su ancho de banda comprende frecuencias que van de 0.5 Hz hasta 30 Hz, y con un rango de amplitudes promedio que oscila entre los $5\mu\text{V}$ y $50\mu\text{V}$ en individuos normales,[20]; aunque en etapas de sueño profundo, la amplitud de la actividad cerebral en ocasiones puede alcanzar los $200\mu\text{V}$,[24].

3.3. Análisis en el tiempo de una señal EEG

El estudio en el dominio del tiempo de las señales EEG se realizaba antes de la popularización de las técnicas frecuenciales, cuando la capacidad de cálculo de las computadoras no era muy poderosa. Hoy en día, estas técnicas pueden seguir siendo utilizadas cuando las especificaciones de nuestra aplicación no demanden mucha precisión, sobre todo son útiles para aplicaciones básicas en tiempo real, por ejemplo el conocer la frecuencia fundamental de una señal.

3.3.1. Análisis de cruces por cero

Este análisis se basa en calcular la función de densidad de probabilidad de el tiempo τ que tarda la señal de EEG en cruzar por cero o por algún otro nivel. En la práctica, esta función se puede estimar calculando un histograma del intervalo de tiempo entre dos cruces sucesivos,[20].

3.3.2. Análisis de autocorrelación

El análisis de autocorrelación,[20], fue muy utilizado en la década de 1950 a 1960, y constituyó la técnica predecesora del análisis espectral de la señal EEG, sin embargo, calcular funciones de autocorrelación era muy costoso para la capacidad de cómputo disponible en aquellos años, por lo que esta técnica no fue ampliamente usada. No obstante se adoptó una versión mas simple del análisis basada en el hecho de que la función de autocorrelación puede aproximarse sustituyendo las señales $x(t)$ y $x(t+\tau)$ por sus signos: +1 para $x(t)>0$ y -1 para $x(t)\leq 0$ como se menciona en [20]. El resultado de esta sustitución da origen a la función conocida como *correlación de coincidencia de polaridad*.

El análisis de autocorrelación perdió atractivo, con el advenimiento de la transformada rápida de Fourier, pues el cálculo de ésta era significativamente más rápido resultando más económico y en términos generales, más poderoso. Aunado a lo anterior, el análisis de autocorrelación hacia más difícil la identificación de más de una frecuencia dominante en la señal, por lo que fue sustituido en su totalidad por el análisis espectral.

3.4. Análisis en el dominio de la frecuencia

A menudo, resulta de mayor utilidad para el análisis de una señal extraer información contenida en el dominio de la frecuencia, por ejemplo, un experto encuentra más ilustrativo saber que la frecuencia cardiaca de un paciente, bajo condiciones normales, es al rededor de $70 \left[\frac{\text{latidos}}{\text{min}} \right]$, en vez de saber que la señal cardiaca tiene un periodo de 0.87 seg.

La característica aleatoria de las señales EEG, implica un cierto grado de complejidad en su análisis; sin embargo, se puede asumir características estacionarias sólo durante períodos cortos de duración donde no se presenten cambios en la actividad cerebral. En [20] se menciona que en la mayoría de los análisis clínicos se considera estacionaria la señal EEG en periodos de 5 a 10 segundos.

Considerando la señal EEG como un proceso estocástico estacionario, una manera de analizarla en el dominio de la frecuencia es a través de su densidad

espectral de potencia

3.4.1. Densidad Espectral de Potencia de la señal EEG

La densidad espectral de potencia (PSD, del inglés, Power Spectral Density) es una forma muy útil de representar la señal EEG en el dominio de la frecuencia. Nos permite reconocer la manera en que la potencia de la señal se reparte a lo largo de su ancho de banda.

La PSD Se define como la transformada de Fourier de la secuencia de correlación de la señal, [1]:

$$S_x(\omega) = \mathcal{F} \{R_x(\tau)\} \quad (3.1)$$

Para su equivalente discreto, la densidad espectral de potencia será:

$$\begin{aligned} S_x(n) &= DFT \{R_x(l)\} \\ &= \sum_{l=0}^{N-1} R_x[l] e^{-j\frac{2\pi}{N}nl} \\ \forall n &= 0, 1, \dots, N-1 \end{aligned} \quad (3.2)$$

Para la estimación de la PSD de la señal EEG podemos señalar 2 enfoques, [22], del procesamiento digital de señales que los investigadores en el área han adoptado: El primero, el enfoque paramétrico, y el segundo el no paramétrico. Estos enfoques engloban una gran cantidad de herramientas utilizadas en la estimación del espectro de potencia, sin embargo en esta investigación sólo expondremos un estimador de cada enfoque.

3.4.2. Periodograma de la señal EEG

El periodograma es un método no paramétrico utilizado en el análisis en frecuencia de las señales como un estimador de la densidad espectral de potencia. El término fue introducido por Schuster en 1906 y significa diagrama

de períodos,[3].

El periodograma se basa en considerar estacionaria una señal aleatoria y dividirla en segmentos de igual longitud a los cuales se les aplica la transformada de Fourier y se extrae su módulo al cuadrado. Sin embargo, el resultado de la transformada es igualmente aleatorio. Una forma de reducir la aleatoriedad es realizar un promedio del módulo de la transformada de cada segmento.

Supongamos que tenemos una señal de longitud NL dividida en L segmentos de tamaño N cada uno, entonces el periodograma promedio se define como,[3]:

$$P_{xx}(f) = \frac{1}{L} \sum_{l=0}^{L-1} \left[\frac{1}{N} \left| \sum_{n=0}^{N-1} x[n + lN] e^{-j2\pi f n} \right|^2 \right] \quad (3.3)$$

3.4.3. Estimación de la densidad espectral de potencia de la señal de EEG mediante el modelo Autorregresivo (AR)

Otra forma para estimar la densidad espectral de potencia de una señal EEG, se basa en la extracción de ciertos parámetros que la definen.

El uso de métodos paramétricos para estimar la densidad espectral de potencia de una señal, tiene como principal objetivo, el solventar ciertas limitaciones que presentan los métodos no paramétricos; tales como: la resolución en frecuencia, o la necesidad de que la cantidad de datos tienda a infinito para que la estimación obtenida se aproxima al verdadero valor de la densidad espectral de potencia,[22].

El cálculo de la densidad espectral de potencia por métodos paramétricos se basa en el modelado de las señales, lo que proporciona una mejor resolución, como se muestra en [29], y reduce la cantidad de datos necesarios para

su tratamiento.

Como ya se mencionó, una señal de EEG puede ser considerada estacionaria, por lo tanto es posible representar la señal modelando sus valores como la salida de un sistema lineal caracterizado por la función de transferencia $H(z)$.

$$H(z) = \frac{B(z)}{A(z)} = \frac{b_0 + b_1z^{-1} + b_2z^{-2} + \dots + b_qz^{-q}}{a_0 + a_1z^{-1} + a_2z^{-2} + \dots + a_pz^{-p}} \quad (3.4)$$

De la ecuación anterior se desprenden 3 modelos de predicción lineal que pueden ser utilizados para estimar la salida de la señal EEG.

El primero, llamado proceso ARMA (Autorregresivo de promedios móviles) de orden (p, q) ; denotado como ARMA (p, q) y cuya función de transferencia es:

$$H(z) = \frac{B(z)}{A(z)} \quad (3.5)$$

El segundo, cuando $q = 0$ y $b_0 = 1$, llamado proceso AR (Autorregresivo) de orden p ; denotado como AR (p) y cuya función de transferencia es:

$$H(z) = \frac{1}{A(z)} \quad (3.6)$$

Finalmente el tercer proceso, cuando $A(z) = 1$, llamado MA (Medias móviles) de orden q ; denotado como MA (q) y cuya función de transferencia es:

$$H(z) = B(z) \quad (3.7)$$

En los tres casos se supone que la entrada al sistema asociado es una secuencia de variables aleatorias independientes con media cero y desviación estandar σ_x^2 .

Como puede observarse encontrar el modelo que represente a nuestra señal EEG se resume al cálculo de los coeficientes b_i y a_i para cualquiera de los tres métodos presentados.

Por simplicidad, en esta investigación hemos escogido el modelo AR, ya que su complejidad de cálculo es menos complicada en relación a los modelos ARMA y MA, siendo ésta función proporcional al orden p^2 escogido para el modelo, lo que hace muy eficiente su uso en sistemas de procesamiento en tiempo real.

Como emplearemos el modelo AR, ahora nuestro problema se centra únicamente en la determinación de los coeficientes a_i .

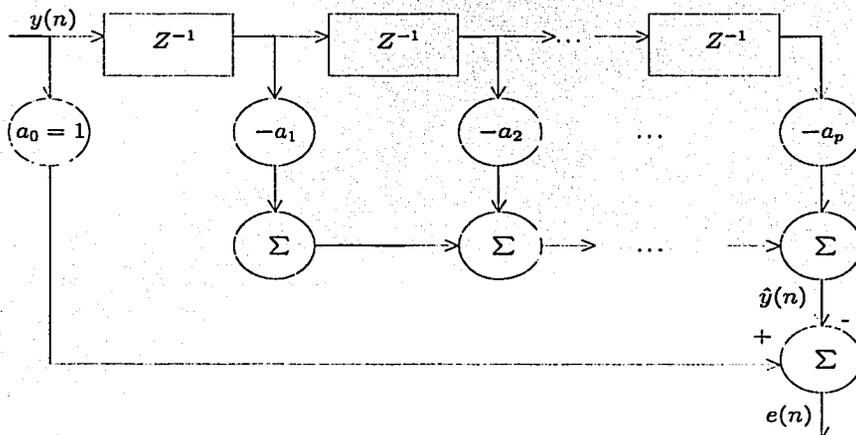


Figura 3.1: Diagrama a bloques de un sistema asociado a un modelo AR

TESIS CON
FALLA DE ORIGEN

La ecuación(3.6) se refiere a la función de transferencia de un sistema asociado a un modelo AR;figura(3.1). Mediante el uso de la anti-transformada \mathcal{Z} y manejando la expresión algebraicamente, obtenemos la ecuación en diferencias del sistema.

$$y[k] = - \sum_{n=1}^p a_n y[k-n] + b_0 e[k] \quad (3.8)$$

Por otro lado, definimos un estimador de $y[k]$ como:

$$\hat{y}[k] = - \sum_{n=1}^p a_n y[k-n] \quad (3.9)$$

El error que se comete al estimar $y[k]$ mediante $\hat{y}[k]$ es:

$$\varepsilon[k] = y[k] - \hat{y}[k] \quad (3.10)$$

Dado que una buena estimación de $y[k]$ es aquella para la cual el error ε es mínimo, es decir minimizaremos el error. Un criterio para la estimación de la señal es minimizar el error cuadrático promedio, (MSE), [1].

El MSE se define como:

$$E \{ |\varepsilon[k]|^2 \} = \sigma^2 \quad (3.11)$$

Escribiendo las ecuaciones(3.8),(3.9),(3.10) con notación matricial,[1],tenemos:

$$y[k] = -A_p^T Y_p[k-1] + e[k] \quad (3.12)$$

$$\hat{y}[k] = -A_p^T Y_p[k-1] \quad (3.13)$$

$$\varepsilon[k] = y[k] + A_p^T Y_p[k-1] \quad (3.14)$$

Donde:

$$A_p^T = [a_1, a_2, \dots, a_{p-1}, a_p]$$

$$Y_p[k-1] = [y[k-1]y[k-2] \dots y[k-p+1]y[k-p]]$$

Se demuestra,[1], que al minimizar la ecuación(3.14) respecto a sus parámetros A_p , obtenemos:

$$R_p A_p = -r_p \quad (3.15)$$

Donde R_p es una matriz *Toeplitz*¹ cuyos elementos son los valores de la función de autocorrelación,[1].

A las ecuaciones del sistema matricial dado por 3.15, se les conoce como ecuaciones normales o de Yule Walker.

$$\begin{pmatrix} R(0) & R(1) & R(2) & \dots & R(p-1) \\ R(1) & R(0) & R(1) & \dots & R(p-2) \\ R(2) & R(1) & R(0) & \dots & R(p-3) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ R(p-1) & R(N-2) & R(N-3) & \dots & R(0) \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \\ a_3 \\ \vdots \\ a_p \end{pmatrix} = \begin{pmatrix} r_1 \\ r_2 \\ r_3 \\ \vdots \\ r_p \end{pmatrix} \quad (3.16)$$

Para resolver las ecuaciones normales de Yule - Walker podemos emplear el método de Levinson - Durbin,[1], apéndice C, el cual aprovecha la estructura *Toeplitz* de la matriz R_p para reducir el número de operaciones requeridas para la inversión de la matriz de p^3 a p^2 ; donde p es el orden

¹Matriz simétrica, positiva definida, cuyos elementos se localizan como se muestra en la matriz R_p de 3.16.

escogido para el modelo AR.

Resolver las ecuaciones de Yule-Walker mediante un modelo autoregresivo implica el conocimiento de la secuencia de autocorrelación R_x de la señal; sin embargo, en la realidad, esta secuencia es raramente conocida por el hecho de que por lo regular contamos con un número finito de muestras de la señal; sin embargo, es posible el uso del modelo si hacemos una aproximación de los valores verdaderos de R_x mediante un estimador.

El polinomio $a_i(z)$ obtenido a partir de la solución de las ecuaciones de Yule walker siempre es estable debido al uso de los valores verdaderos de la secuencia de autocorrelación, pero al usar valores estimados se corre el riesgo de que el polinomio no siempre sea estable, por lo que la selección de un buen estimador es de vital importancia.

Un buen estimador para R_x cuando $m < N$ es el siguiente

$$R_x(m) = \frac{1}{N} \sum_{n=0}^{N-|m|-1} x(n)x(n+|m|) \quad m \geq 0 \quad (3.17)$$

De acuerdo con [3], el uso de la ecuación(3.17) garantiza que el polinomio obtenido al resolver las ecuaciones de Yule Walker

$$\hat{a}_i(z) = 1 + \hat{a}_{i,1}z^{-1} + \dots + \hat{a}_{i,i}z^{-i}$$

será estable para cualquier i comprendida entre $1 \leq i \leq N - 1$

Una vez estimados los parámetros a_i , la densidad espectral de potencia de la señal EEG se obtiene como: [22]

$$\Gamma_{xx}(f) = |H(\omega)|^2 \Gamma_{ww}(f) \quad (3.18)$$

Donde $\Gamma_{ww}(f)$ es la densidad espectral de potencia de la secuencia de entrada, y $H(\omega)$ es la respuesta en frecuencia del modelo.

Consideraremos el ruido blanco como la secuencia de entrada de nuestro modelo, por lo que la densidad espectral de potencia resulta: [22]

$$\Gamma_{xx}(f) = \frac{\sigma_w^2}{A(z)|_{z=e^{j2\pi fT}}} \quad (3.19)$$

Donde:

$$A(z) = 1 + a_1z^{-1} + a_2z^{-2} + \dots + a_pz^{-p}$$

T=Intervalo de muestreo

$$e^{j2\pi fT} = \cos(2\pi fT) + j \sin(2\pi fT)$$

3.5. Conclusiones

Los conceptos y métodos aquí presentados no son los únicos y tampoco los mejores que se aplican en el procesamiento de las señales EEG. Hoy en día, el estado del arte en cuestión de procesamiento de señales EEG ha evolucionado enormemente; sin embargo, éstos algoritmos siguen la tendencia clásica del procesamiento digital de señales y como revela la literatura, han demostrado dar buenos resultados. Por esta razón decidimos tomarlos como herramientas para la extracción de características; sin olvidar que estas herramientas presentan limitaciones que pudieran en un dado caso ocasionar una mala interpretación de los resultados.

Capítulo 4

Elementos para la clasificación de señales EEG

4.1. Introducción

El propósito final del análisis de señales biomédicas es poder clasificarlas de acuerdo a un conjunto de características para ayudar a emitir un diagnóstico médico,[23].

La clasificación de una señal EEG es importante porque sirve como base para realizar muchas aplicaciones, por ejemplo a partir de la clasificación se construyen hipnogramas que ilustran la sucesión de fases durante el sueño,[29], también, a partir de la clasificación de las señales EEG es posible establecer un canal de comunicación con el medio externo al ser capaces de identificar los distintos tipos de actividad cerebral que un individuo pudiera evocar,[28].

La clasificación es un proceso donde se forman grupos de elementos con características si no iguales, muy parecidas unas de otras. Dichos grupos reciben el nombre de clases.

En la actualidad se cuentan con varios algoritmos enfocados a realizar la clasificación de patrones,[13]; los más simples funcionan evaluando funciones de distancia, le siguen aquellos que implementan funciones de decisión basadas en probabilidad y estadística, y finalmente, los algoritmos de clasificación más complejos implementan herramientas inteligentes como redes neu-

ronales o algoritmos genéticos,[23]. Por su simplicidad, durante este capítulo estudiaremos sólo aquellos que trabajan mediante la evaluación de distancias.

4.2. Clasificación de patrones

El reconocimiento e interpretación de ciertas características de interés de una señal se logra una vez que éstas han sido aisladas de aquéllas sin relevancia y han sido identificadas. De esto se encarga el procesamiento de las señales; por lo que el siguiente paso es la clasificación de estas características y el agrupamiento de ellas en conjuntos de elementos que comparten cierta similitud. Una vez que se han formado grupos de características, entonces se puede tomar decisiones. Ver figura(4.1).

Un *patrón* es un conjunto de características similares o particulares. Mientras que cada conjunto de patrones es denominado *clase*.

La clasificación de patrones se entiende como el agrupamiento en M clases plenamente identificables, representadas por el vector z_i , $i = 0 \dots M - 1$; a través de la extracción de características o atributos comunes entre los datos; representados por un vector $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$, llamado *vector de características*; donde cada x_i representa valores que caracterizan la señal como coeficientes de autocorrelación, cruces por cero, valores de frecuencia, valores de potencia, parámetros a_i asociados a un modelo autoregresivo; etc. En esta investigación, los elementos de nuestro vector de características, serán los coeficientes de autocorrelación y los parámetros a_i (secciones 3.3.2,3.4.3).

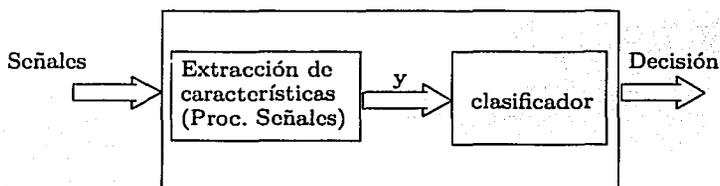


Figura 4.1: Esquema básico del reconocimiento de patrones

No existe ninguna regla que indique los patrones de características apro-

piados para una cierta aplicación, lo que en ocasiones implica un proceso de prueba y error, sin embargo la elección de las características debe considerar los siguientes criterios,[13]:

- **Discriminación:** Las características deben tomar valores significativamente diferentes para elementos pertenecientes a diferentes clases.
- **Fiabilidad:** Las características deben tomar valores similares para todos los elementos de una misma clase.
- **Independencia:** Las características a elegir para la clasificación no deben de estar correlacionadas entre sí, es decir, que no dependan entre ellas, pues finalmente estarían representando una misma característica.

Antes de que un sistema clasificador pueda comenzar a clasificar, éste deberá primero de estar *definido y entrenado*.

Se habla de un sistema *definido*, [13], cuando se han establecido las reglas para decidir la pertenencia a una clase de un elemento en función de los valores de su patrón; por ejemplo, funciones de distancia.

Se habla de que un sistema está *entrenado*, [13], cuando se han establecido los valores o rango de valores que definen a cada clase. Dentro del entrenamiento podemos distinguir dos enfoques:

Entrenamiento Supervisado,[23]: Los valores de los patrones de cada clase se obtienen en base a un grupo de objetos conocidos, patrones de comparación, los cuales representan toda la gama posible de clases que pueden identificarse. Gráficamente el entrenamiento supervisado se ilustra en la figura(4.2)

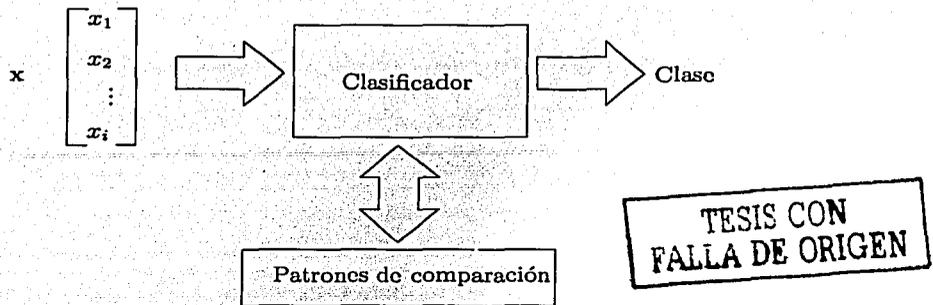


Figura 4.2: Entrenamiento Supervisado

Entrenamiento no supervisado, [23]: No se conocen las clases de objetos que puedan identificarse ni sus posibles valores. Se estiman las tendencias de agrupamiento de los objetos de acuerdo a las muestras disponibles.

4.3. Funciones de distancia

Dado que el grado de similitud es fundamental para definir los elementos de una clase, es necesario contar con un mecanismo de medida. Una manera de decidir cuan parecidas o no son las características de los datos respecto a una clase es por medio de las funciones de distancia. Toda función de distancia debe cumplir con lo siguiente, [11]:

- $d(x,z)=d(z,x)$
- $d(x,z)>0$ para $x \neq z$
- $d(x,x)=0$
- $d(x,z) \leq d(x,y)+d(z,y)$

Se han definido múltiples funciones de distancia, pero en este trabajo sólo empleamos dos de ellas:

- *Distancia de Chebyshev*, [29]: La distancia de Chebyshev entre un vector \mathbf{x} y el representante de clase \mathbf{z} se define como:

$$D_c = \text{Max}|\mathbf{x} - \mathbf{z}| \quad (4.1)$$

Donde la menor distancia indica una gran similitud entre el vector y el representante de la clase.

- *Distancia espectral RMS logarítmica*, [11]: Esta distancia se utiliza para realizar comparaciones entre modelos espectrales de la forma:

$$H = \frac{\sigma}{A(z)}$$

Se define el error o la diferencia entre modelos como:

$$V(\theta) = \ln \left[\frac{\sigma_1^2}{|A_1(e^{j\theta})|^2} \right] - \ln \left[\frac{\sigma_2^2}{|A_2(e^{j\theta})|^2} \right] \quad (4.2)$$

La distancia espectral RMS se define como:

$$(dp)^2 = \int_{-\pi}^{\pi} |V(\theta)|^2 d\theta \quad (4.3)$$

4.4. Algoritmo de clasificación

El algoritmo que a continuación mostramos, es de los más sencillos y Rangaraj[23], lo nombra Algoritmo de Asignación de Clases Simple.

Supongamos que tenemos N datos: $\{x_1, x_2, \dots, x_n\}$

1. Hacer el centro de la primera clase \mathbf{z}_1 igual a cualquier elemento. por ejemplo: $\mathbf{z}_1 = \mathbf{x}_1$
2. Escoger un umbral θ no negativo.

3. Calcular la distancia D_{21} entre x_2 y z_1 . Si $D_{21} < \theta$, asignar x_2 a z_1 ; si no, x_2 forma una nueva clase de manera que $z_2 = x_2$.
4. Si x_i se agrega a una clase z_j , actualizar el centro de masa de la clase de acuerdo a:

$$z_j = \frac{1}{n_p + 1} [n_p * z_j + x_i] \quad (4.4)$$

Donde:

z_j = Vector representante de la clase j

n_p = Número de segmentos de datos representados por la clase z_j

x_i = Segmento actual a clasificar

5. De manera general, calcular la distancia $D_{ij} \forall x_i, z_j; i = 3, \dots, N$ y $j = 1, \dots, M$: donde M es el número de clases formadas.

Nota: En caso de que para varias clases se cumpla que: $D_{ij} < \theta$, se tomará la menor distancia.

Este algoritmo, aunque resulta muy sencillo, tiene la desventaja de que las clases formadas dependen del valor de θ , de la primera clase formada, y el orden en que se manejen los vectores x . No obstante estas desventajas, el algoritmo fue implementado por Zepeda[29] para clasificar actividad eléctrica cerebral. Demostró tener un buen desempeño cuando los datos de entrada son los coeficientes de autocorrelación de la señal EEG a clasificar, y la función de distancia es la distancia de Chebyshev; por lo que en esta investigación lo usaremos para realizar la parte de clasificación.

Al igual que para la selección de características, no existe alguna regla que nos indique que algoritmo de clasificación se debe usar en una cierta aplicación, por lo que el algoritmo de clases simple, no sería el único que pudiera ser usado. Existe gran cantidad de algoritmos de clasificación. Una revisión de algunos de ellos puede encontrarse en [14].

4.5. Conclusiones

La clasificación de señales EEG es una tarea complicada debido a la naturaleza variable y dinámica de su representación. La representación de la señal EEG mediante un conjunto de características juega un papel muy importante en el proceso de clasificación, éste le permite al clasificador conocer la estructura de la señal por medio de la interrelación de sus elementos. Mientras mayor sea la cantidad de elementos en el conjunto de características, el clasificador tendrá un mayor conocimiento de la señal. Lo anterior sugiere que la elección del algoritmo de clasificación es de suma importancia, ya que el algoritmo de clasificación deberá adecuarse a las propiedades del conjunto de características.

En nuestra investigación, hemos optado por un clasificador que se adecua fácilmente a nuestro conjunto de características mediante funciones de distancia, que en nuestro contexto son la distancia de Chebyshev y la distancia espectral RMS. La distancia de Chebyshev, como se muestra en [29] resulta ser muy barata en cuestión de cálculo y a la vez adecuada para conjuntos de características formados por coeficientes de autocorrelación; mientras que la distancia espectral es aplicable a conjuntos de características extraídos de la densidad espectral de potencia de la señal.

Capítulo 5

Interfaces Hombre Máquina mediante señales EEG

5.1. Introducción

La idea de crear interfaces hombre máquina mediante señales de EEG, BCI (Brain Computer Interfaces) por sus siglas en inglés, es relativamente nueva, se tienen referencias que en 1967,[16], Edmond Dewan experimentó la utilización del ritmo Alfa para producir caracteres en código Morse. La verdadera investigación sobre las BCIs, comenzó en en la década de los 70's,[16], cuando el departamento de defensa de los Estados Unidos comenzó a desarrollar un sistema que permitiría a sus pilotos volar avionces de combate por medio de sus mentes, sin embargo, la tecnología de la época y sus conocimientos sobre el tema hicieron que el proyecto fuera cancelado. No fue sino hasta finales de la década de los 80's cuando el número de investigadores dedicados a establecer un canal de comunicación por medio de señales EEG entre un individuo y el medio ambiente aumentó,[16]. En 1988 Farwell y Donchin,[9], investigadores de la Universidad de Illinois trabajaron en un sistema basado en el potencial P300 que permitía seleccionar letras de una pantalla. A la fecha, existen más de 20 grupos dedicados a la investigación relacionada con las BCIs,[16], la mayoría enfocadas en aplicaciones de control de prótesis, control de ratones de computadora y sistemas de selección.

Para lograr la comunicación entre un cerebro y una computadora, se han establecido dos enfoques, el primero que realiza su objetivo por medio de un

clasificador que identifica la aparición de patrones de actividad EEG asociados a ciertas tareas mentales o estímulos sensoriales conocidos como actividad psicológica exógena; y el segundo, basado en la generación de actividad endógena, en otras palabras, en la capacidad de producir a voluntad patrones EEG previamente establecidos que el sistema pueda interpretar como comandos,[16].

En Junio de 1999, durante la primera reunión dedicada a las BCIs en Rensselaerville Institute en Albany, Nueva York, se acordó una definición en la cual se expresa que estos sistemas son aquellos que establecen un canal de comunicación entre el cerebro de un individuo y el mundo exterior sin la intervención de músculo alguno,[27].

Una BCI, entre otras aplicaciones, permite a las personas que padecen desórdenes neuromusculares comunicarse o controlar el mundo externo. Con este fin se han hecho estudios para desarrollar dispositivos tales como joy-sticks, ratones, teclados, controladores para sillas de ruedas, entre muchos otros.

5.2. Modelo Funcional de una BCI

Las BCIs pueden ser tan simples, o tan complejas como nuestros recursos humanos, tecnológicos y económicos nos permitan; sin embargo, con el fin de poder intercambiar información y realizar comparaciones con el trabajo de otros expertos, es necesario estandarizar el nombre y la función de cada uno de los elementos que conforman una interface.

Manson[17], propone un modelo funcional básico para la estandarización de estas interfaces con los siguientes elementos:

Usuario El *Usuario* es la persona que controla el *Dispositivo* en la interface modificando intencionalmente su actividad cerebral.

Adecuación En esta parte se realiza la adquisición de la señal EEG. Básicamente se compone de:

- **Electrodos:** Los *Electrodos*, vistos en sección 2.2.1, convierten la actividad cerebral del *Usuario* en señales eléctricas.

- **Amplificadores:** Los *Amplificadores* amplifican, vistos en sección 2.2.2, y filtran, sección 2.2.3, las señales eléctricas del *Usuario*.

- **Convertidor analógico digital:** El convertidor analógico digital, visto en sección 2.2.4, realiza el muestreo y cuantización de la señal analógica de entrada.

Extracción de características . La parte de *Extracción de características* transforma las señales amplificadas en valores representativos correspondientes a la actividad cerebral del *Usuario* mediante la implementación de algún algoritmo del procesamiento digital de señales como los revisados en la sección 3

Mapeo de características . El *Mapeo de características* clasifica los distintos vectores de características mediante algún algoritmo de clasificación, sección 4.4, y la decisión que se toma la traduce en señales lógicas de control. Es importante no confundir con los conceptos matemáticos de mapeo y transformación.

Interface de control . La *Interface de control* traduce las señales lógicas de control en señales que tengan un significado para el *Dispositivo*. Se compone de tres partes:

- Selección de características.
- Interface de estado de control.
- Generación de señales de control.

Controlador de dispositivo . El *Controlador de dispositivo* se encarga de traducir las señales de la *Interface de control* en señales físicas inhe-

rontes al *Dispositivo*.

Dispositivo . Existen un amplio rango de *Dispositivos* que pueden ser usados en las BCIs, desde sillas de ruedas, prótesis neurales, hasta electrodomésticos; sin embargo, en la actualidad, la mayoría de los dispositivos usados hasta la fecha han sido dispositivos de entrada de computadoras como en los experimentos de Wolpaw[28], McMillan[18], Sutter[25], entre otros.

Ambiente de operación . El *Ambiente de operación* describe los elementos y factores del medio donde el *Dispositivo* va a operar, por ejemplo superficies, temperaturas, ruido, etc..

5.3. Taxonomía de las BCI

La relación e integración del modelo funcional de una BCI dentro de todo un contexto de desarrollo se conoce como taxonomía de la BCI. Mason[17], propone la siguiente taxonomía:

Población :

Descripción : Descripción de las personas para las cuales el sistema BCI está diseñado

Necesidades : Descripción de los objetivos personales del usuario o de las necesidades que atiende el diseño.

Tareas :

Descripción : Relacionado con las necesidades de la población, se describen las tareas que el sistema BCI debe realizar.

Medio ambiente :

Descripción : Características físicas y sociales del entorno donde el sistema BCI será usado.

Control de la interface cerebral :

Neuro-mecanismo : Descripción de los mecanismos neurológicos o procesos que el usuario usa para generar el control de las señales de EEG.

Entrada : Descripción de la fuente de señal

Control Usuario : Define si las señales de control son continuas o intermitentes.

Extracción de características : Descripción de los métodos utilizados para la extracción de características.

Mapeo de características : Descripción de los métodos utilizados para mapear las características a un espacio de decisiones.

Salidas : Descripción del número de salidas del control de la interface y sus características.

Interface de control :

Entrada : Descripción y número de entradas a la interface de control y sus características

Traducción semántica : Descripción semántica de la traducción de las señales lógicas de control

Salida : Descripción y número de salidas de la interface de control y sus características

Despliegue del control : Descripción del despliegue de control si es que éste existe

Mecanismo de estimulación : Descripción del mecanismo de estimulación si es que éste existe

Dispositivo :

Descripción : Descripción general del dispositivo empleado

Retroalimentación : Descripción de la manera en que se realiza la retroalimentación entre el usuario y el dispositivo.

Controlador de Dispositivo :

Entradas : Descripción y número de entradas al controlador de dispositivo

Descripción del funcionamiento Descripción de cómo las semántica de control se traduce en señales físicas de control para el dispositivo.

5.4. Clasificación de las BCI

Las interfaces BCI se clasifican de acuerdo al tipo de actividad que registran: actividad de índole endógena, o actividad de índole exógena. Además del tipo de actividad que registran, las BCIs pueden clasificarse de acuerdo a su tipo y modo de operación. Las BCIs pueden ser, [16] :

Invasivas o no invasivas: Esta clasificación se refiere principalmente a la forma en que la actividad cerebral es registrada, sección 1.5, porque los electrodos usados para el registro pueden ser electrodos de superficie, como los presentados en la sección 2.2.1, en el caso de registros de electroencefalografía; o electrodos intracraneales, cuando se hacen registros de E-EEG, por ejemplo, para los cuales es necesario recurrir a técnicas quirúrgicas para su colocación. Sección 1.5. Actualmente, la mayoría de las interfaces hombre máquina se llevan a cabo mediante electrodos de superficie, que resultan ser más prácticos para su uso, pero sacrifican la calidad de la señales registradas.

Síncronas o asíncronas: En las interfaces asíncronas, las señales de EEG son monitorizadas de manera constante, lo que implica que el sistema debe ser capaz de distinguir cuando la persona está generando una señal comando y cuando no. En el modo síncrono, el sistema se inicializa y a partir de ese momento comienza el control mediante la interface.

Universales e individuales: Las interfaces universales son aquellas que son capaces de funcionar con las señales EEG de cualquier persona; sin embargo, se sabe que las características fisiológicas y psicológicas de las personas no son iguales; lo que obliga a los investigadores a tomar ciertos parámetros particulares de cada uno con la finalidad de aumentar el desempeño de la interface. Por lo tanto estas interfaces difieren de persona a persona por lo que, en este caso son llamadas interfaces individuales.

En línea y fuera de línea : Actualmente las investigaciones se enfocan al desarrollo de interfaces en línea, las cuales, registran, procesan y

actúan en tiempo real; esto supone un costo computacional elevado. Otro tipo de interfaces, llamadas fuera de línea, almacenan un gran volumen de datos que después son procesados de manera conjunta y emiten un resultado, por supuesto estas interfaces son usadas en aplicaciones donde el tiempo de procesamiento no está comprometido.

5.5. Mecanismos Neurológicos comunmente utilizados en BCI

El número de investigadores que actualmente se dedica al desarrollo de BCIs va en aumento, gran parte del trabajo de estas personas lo dedican a la búsqueda de técnicas y mecanismos cada vez mas exactos para el desarrollo de dichas interfaces. A continuación se presentan algunos mecanismos neurológicos que han sido usados en el desarrollo de sistemas BCI.

5.5.1. Detección del potencial evocado P300

En 1965, Sutton [26] observó en sujetos sanos que, en el registro de EEG, se obtenía un potencial positivo aproximadamente 300 milisegundos después de un tono de estimulación auditiva infrecuente, pero no después de uno frecuente. A esta respuesta se le conocería como el componente P300, la cual se convirtió en uno de los potenciales evocados más conocidos y confiables.

Con base a la respuesta P300 [4] del sistema nervioso central, en 1988 los investigadores Farwell y Donchin del laboratorio de psicofisiología de la universidad de Illinois [9], describieron una técnica para detectar el potencial evocado P300, mediante el registro de actividad eléctrica cerebral en la zona parietal. Para obtener el potencial evocado P300, Farwell y Donchin utilizaron una técnica de estímulo conocida como "*paradigma del elemento extraño*", que consiste en presentar estímulos de ocurrencia constante entre mezclados con otros de ocurrencia aleatoria. El propósito del experimento fue descubrir el número mínimo de estímulos, presentados por intervalos de tiempo, necesarios para detectar la respuesta P300. El trabajo de Farwell y Donchin concluye diciendo que 36 estímulos de ocurrencia constante pueden ser detectados con 95 % de exactitud dentro de un periodo de 26 segundos.

5.5.2. Acondicionamiento del ritmo μ

Esta técnica fue descrita principalmente por Wolpaw en 1991 [28]. Fue usada para mover el puntero de un ratón y se basa en la capacidad de un individuo para controlar la amplitud del ritmo μ mediante sesiones de entrenamiento; en las cuales, Wolpaw pedía a los sujetos que imaginasen el movimiento que deseaban producir. Wolpaw define la amplitud del ritmo μ como la raíz cuadrada de la potencia del espectro de EEG a 9 Hz. En su experimento, Wolpaw, registra la actividad cerebral en la región central del cráneo. Mediante algoritmos de decisión basados en la energía del espectro de la señal EEG, se desplazaba el puntero del ratón hacia arriba, si es que la potencia aumentaba, o hacia abajo, si es que disminuía. Sus estudios realizados desde hace más de 15 años, han demostrado que la gente con o sin discapacidades motrices puede aprender a controlar la amplitud del ritmo μ , y puede usar este aprendizaje para controlar el desplazamiento del puntero del ratón en una o dos dimensiones.

5.5.3. Detección de potenciales evocados visuales

Erich Sutter (1992)[25] en el Smith-Kettlewell Eye Research Institute de San Francisco CA, trabajó interfaces basadas en el potencial evocado visual; para ello utilizó 64 cuadros de color verde y rojo que representaban las letras del alfabeto inglés, los cuales debían ser observados durante cierto tiempo para formar una palabra. Setenta individuos normales fueron capaces de conseguir formar una palabra en intervalos de 1 a 3 segundos por letra. Sutter sugiere la necesidad de mejorar la colocación de electrodos y la forma de estímulo para mejorar sus resultados.

Otro investigador que realizó estudios sobre el potencial evocado visual fue Cilliers (1993) [6] en el departamento de ingeniería eléctrica de la universidad de Pretoria, Sudáfrica. Su experimento consistió en generar un potencial evocado por medio de LEDs modulados con una onda senoidal de 10 Hz. A cada led le asoció una tecla de un teclado multicolor que aparecía en una computadora. La tecla correspondiente se seleccionaba observando su LED asociado.

5.5.4. Detección de diferencias entre hemisferios laterales

Esta técnica fue utilizada por Drake en 1993 [8]; para ello colocaba a los sujetos en estudio un par de audífonos y transmitía mensajes con los que los individuos estaban de acuerdo o en desacuerdo, de manera independiente a través del audífono izquierdo, derecho o ambos. Sus estudios concluyeron que se presentaban asimetrías en ambos hemisferios del cerebro cuando un mensaje con el que se estaba de acuerdo se transmitía por un audífono y otro con el que se estaba en desacuerdo se presentaba por el otro.

5.6. Conclusiones

Las interfaces hombre máquina controladas por señales EEG más desarrolladas y con mejores resultados hasta la fecha se basan en la extracción del ritmo Alfa y en el acondicionamiento del ritmo μ , siendo esta última la actividad cerebral que más fácilmente puede ser controlada a voluntad. El control sobre la actividad μ puede ser aprendido como se demuestra en [28] por medio de recuerdos, imaginación de movimiento, risas, masticación, deglución y otras actividades motoras.

Otras interfaces, que no han tenido tan buen éxito como las anteriores, pero no por ello dejan de dar buenos resultados, son las interfaces que funcionan mediante el uso de potenciales evocados; una desventaja de este tipo de interfaces para ciertas aplicaciones es que se hace imperiosa la necesidad de tener un estímulo externo que genere el potencial evocado, por lo que cada vez que requiriéramos de un comando para manipular el entorno, primero deberíamos someternos al estímulo sensorial, esto le resta automatismo a la interface.

A pesar de que las interfaces mediante EEG aún son pobres eficientemente comparadas con interfaces controladas por voz, por señales miocelétricas u oculares; y haciendo a un lado sus deficiencias y limitaciones, la idea de comunicarse con el entorno usando señales EEG, es totalmente realizable y su campo de aplicación es enorme, principalmente en el área médica y militar.

Capítulo 6

Implementación de una interface hombre máquina

6.1. Introducción

En este capítulo proponemos una interface cerebral adecuando el modelo descrito por Mason [17] y presentamos los elementos de software que constituyen los bloques de procesamiento digital y de clasificación de la señal EEG.

La interface que proponemos, en primera instancia, caracteriza y clasifica la señal EEG en dos estados: "ojos abiertos" y "ojos cerrados". Su funcionamiento se basa en la inhibición de la actividad Beta, que es característica de los estados de vigilia y concentración. Esta inhibición se produce con la aparición repentina de la actividad Alfa cuando el usuario de la interface se relaja y cierra los ojos.

6.2. Diseño de nuestra Interface

Para alcanzar nuestro objetivo adecuamos el modelo funcional descrito en la sección 5.2., como se muestra en la figura 6.1 y a continuación se detalla en su taxonomía.

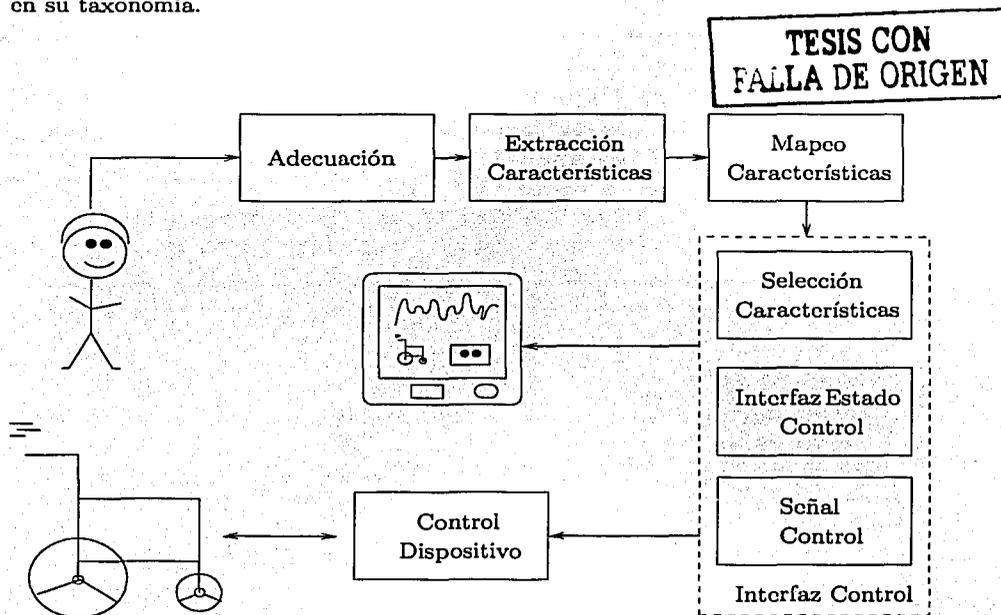


Figura 6.1: Arquitectura propuesta de una BCI

6.2.1. Taxonomía de nuestra interface

Tomamos como modelo la taxonomía revisada en la sección 5.3, y la hemos adecuado a nuestros intereses como sigue:

Población :

Descripción : Individuos sin discapacidades aparentes

Necesidades : Investigación y pruebas

Tareas :

Descripción : Generar comandos de control para un relevador u optoacoplador que a su vez controla el estado de un interruptor eléctrico

Medio ambiente :

Descripción : Ninguno en particular. El medio ambiente fue creado con fines de prueba del sistema y corresponde al entorno de un interruptor eléctrico con el que descamos interactuar

Control de la interface cerebral :

Neuro-mecanismo : Inhibición de la actividad Beta mediante el cierre de ojos

Entrada : Señal de EEG perteneciente al canal O2A1

Control Usuario : Continuo

Extracción de características : El vector de características fue obtenido a partir de la función de autocorrelación sesgada, el modelo autorregresivo de la señal y el cálculo de su densidad espectral de potencia

Mapeo de características : El mapeo de características fue implementado mediante la función de distancia entre patrones muestra y el segmento analizado

Salidas : Se obtiene una sola salida con el valor de la función de distancia.

Interface de control :

Entrada : Una sola entrada correspondiente al valor de la función de distancia obtenida del Mapco de características

Traducción semántica : Ojos cerrados, ojos abiertos

Salida : Una sola salida lógica que representará ojos cerrados u ojos abiertos

Despliegue del control : En la pantalla de la computadora se muestra un recuadro ilustrativo de la actividad cerebral

Mecanismo de estimulación : No existe un mecanismo de estimulación, el usuario abre y cierra los ojos a voluntad para inhibir la actividad Beta correspondiente a ojos abiertos, siendo ésta sustituida por actividad Alfa

Dispositivo :

Descripción : El dispositivo semeja un interruptor eléctrico cuya activación o desactivación dependerá del estado ojos abiertos u ojos cerrados

Retroalimentación : La retroalimentación se realiza de manera directa entre el usuario y el dispositivo, ya sea por él mismo para el caso ojos abiertos, o por ayuda de un tercero en caso de ojos cerrados

Controlador de Dispositivo :

Entradas : Recibe una entrada proveniente del puerto serie de la computadora con un nivel lógico de 0 para ojos abiertos y 1 para ojos cerrados

Descripción del funcionamiento El controlador recibe un nivel lógico del puerto serie de la computadora, si éste corresponde a un nivel lógico 1, un optoacoplador abrirá el circuito y viceversa

6.3. Adquisición de las señales

En el laboratorio de trastornos del sueño, en la facultad de psicología UNAM, en coordinación con las Doctoras Rosa María Campos y Matilde Valencia; se realizó un registro de mi actividad cerebral, en donde de manera

alcatoria, mantenía los ojos abiertos con el objeto de generar ritmo Beta para posteriormente bloquearlo mediante el cierre de ojos y la aparición de ritmo Alfa. Las características del registro fueron las siguientes:

Duración del Registro : 20 minutos

Actividades : Abrir y cerrar los ojos en intervalos de tiempo variables

Número de canales : 4

Descripción de canales : De acuerdo al sistema de colocación 10-20, el montaje usado fue el siguiente

- C3A2
- O2A1
- C4A1
- O1A2

Frecuencia de Muestreo : 100 Hz en cada uno de los canales.

6.4. Preprocesamiento de la señal EEG

Cada uno de los cuatro canales del registro fue separado en archivos individuales. En esta investigación trabajamos sobre el canal de O2A1, el cual registra la región occipital, lugar donde se hace más evidente la actividad Alfa que aparece al cerrar los ojos.

Como es común en registros de EEG, fue necesaria la remoción de los llamados artefactos de la señal. Los artefactos son elementos ajenos a la actividad EEG que aparecen en el registro; éstos, son atribuibles entre otras causas al movimiento de ojos, a la sudoración, al tono muscular, etc. Esta parte del procesamiento, se realizó, tomando la idea de [5], con la función *artifact*, cuyo código aparece en el apéndice B. Esta función atenúa el efecto de las frecuencias bajas propias de artefactos de ojos y de las frecuencias altas debido a músculo al filtrar la señal mediante un filtro paso banda con frecuencias de corte de los 7 Hz a los 32 Hz

6.5. Módulo para el procesamiento de señales EEG

La parte de procesamiento se encarga de la extracción de características de la señal EEG que servirán de entrada al clasificador.

Se manejan tres esquemas básicos para la extracción de características, ver sección 3:

1. Funciones de autocorrelación y potencia de la señal
2. Técnicas frecuenciales basadas en la transformada de Fourier discreta (DFT)
3. Modelando la señal EEG como un proceso autorregresivo

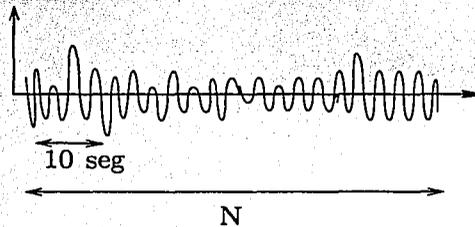


Figura 6.2: Segmentación de la señal EEG

De manera general, para cada uno de los esquemas propuestos, el procesamiento se realizó por bloques de datos de 10 segundos, figura(6.2), para los cuales, de acuerdo con [20], la estacionaridad de la señal no se compromete.

6.5.1. Extracción de características basada en correlación y potencia

Este esquema es el más simple. Se sabe que el elemento cero de la secuencia de autocorrelación, representa la potencia de una señal. Por otra parte, de

acuerdo con [29], una buena representación de las características espectrales de una señal EEG se obtiene calculando los primeros 16 coeficientes de su función de autocorrelación, por lo que éste será el número de coeficientes de autocorrelación que calcularemos.

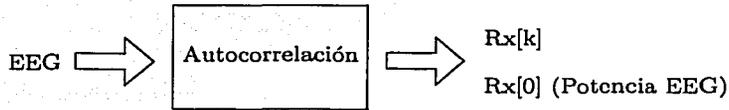


Figura 6.3: Extracción de características mediante autocorrelación y potencia

Implementación en software

Nuestro diagrama de flujo para la extracción de características mediante funciones de correlación y potencia se muestra en la figura 6.4.

De acuerdo a la segmentación propuesta, contamos con L bloques. Para cada bloque se obtiene su función de autocorrelación y su potencia. Adicionalmente pudiera calcularse la pendiente representativa de la curva de autocorrelación, sus cruces por cero, su "frecuencia fundamental"¹, etc.; con el fin de obtener características adicionales para la clasificación.

La función `acorrb`: Calcula la secuencia de autocorrelación sesgada (3.17) de un bloque de datos x .

Uso: `Rx=acorrb(x,m);`

Donde:

x : Secuencia de entrada.

m : Número de elementos de la secuencia de autocorrelación a calcular

Rx : Secuencia de autocorrelación de longitud m devuelta por `acorrb`.

¹Lo denotamos entre comillas porque la frecuencia fundamental se obtiene sólo si se trata de una función periódica, en otro caso se considera una estimación.

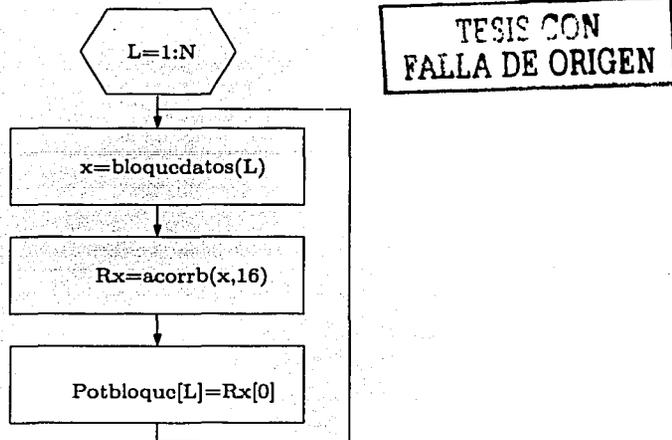


Figura 6.4: Diagrama de flujo para la extracción de características mediante correlación y potencia

La potencia de cada bloque se obtiene del elemento cero de la función de correlación

6.5.2. Extracción de características basada en FFT y PSD

La transformada rápida de Fourier (FFT), y la estimación de la densidad espectral de potencia (PSD), son, actualmente, los métodos más utilizados para el análisis y procesamiento de señales EEG. Aunque su grado de complejidad y tiempo de cálculo aumenta respecto al esquema basado en correlaciones, por medio de estas herramientas se obtiene información adicional acerca de la señal que resulta relevante al ser trasladada a un espacio de representación frecuencial.

Debido a las características aleatorias de nuestra señal, en este esquema de procesamiento, emplearemos el estimador de la densidad espectral de po-

tencia dado por $\hat{S}_x = |FFT\{Rx\}|^2, [1]$, donde \hat{S}_x es el módulo al cuadrado de la transformada de Fourier de la secuencia de autocorrelación de la señal EEG de entrada. \hat{S}_x es considerado un estimador adecuado de la PSD.

En esta parte debemos considerar, que el estimador propuesto mejora su desempeño cuanto mayor sea el número de elementos de la secuencia de entrada, sin embargo, en la función de autocorrelación ocurre lo contrario, pues cuanto mayores sean los retrasos calculados, la estimación empeora. Para compensar lo anterior añadiremos ceros a la función de autocorrelación hasta completar 1024 muestras.

Implementación en software

El diagrama de flujo propuesto para esta estrategia se muestra en la figura 6.5.

La función `acorrb`: Calcula la secuencia de autocorrelación sesgada de un vector de entrada, cuya utilización ya ha sido especificada.

`myfft`: Calcula N puntos de la transformada discreta de Fourier (de una manera más rápida) de una secuencia de entrada; N está dado por la longitud de la secuencia de entrada.

Uso: `tf=myfft(Rx);`

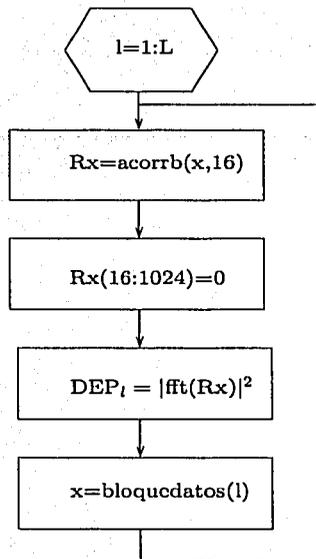
Donde:

`Rx`: Secuencia de entrada. La hemos llamado `Rx` porque bajo este esquema de procesamiento, la entrada a esta función será la secuencia de autocorrelación

`tf`: N puntos de la transformada de Fourier

6.5.3. Extracción de características basada en el modelo AR

Esta técnica se basa en la extracción de parámetros de la señal de entrada modelada como un proceso autorregresivo, ver sección 3.4.3.



TESIS CON
FALLA DE ORIGEN

Figura 6.5: Diagrama de flujo para la extracción de características mediante DFT y PSD

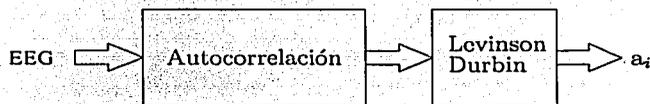


Figura 6.6: Diagrama a bloques para la obtención de los coeficientes a_i

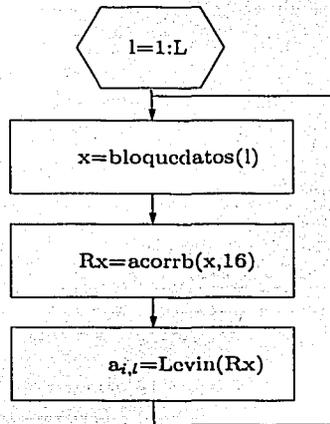
Como se revisó en la sección de procesamiento digital de señales EEG, el modelado de la señal comienza con el cálculo de su función de autocorrelación. Por las razones ya expuestas, se calcularán los primeros 16 coeficientes de autocorrelación. Para ello se propone el uso del estimador sesgado, ya que una

de las principales ventajas de su uso es que nos garantiza que la matriz de autocorrelación de las ecuaciones de Yule Walker eq(3.16) tendrá una estructura Toeplitz; lo que facilita la extracción de su inversa utilizando algoritmos adecuados.

A continuación utilizamos el algoritmo de Levinson Durbin, ver sección 3.4.3, y calculamos los coeficientes a_i para una función de transferencia todo polo de orden 16.

Implementación en software

Para la extracción de los parámetros a_i del modelo autorregresivo, el diagrama de flujo a seguir será el que se muestra en la figura(6.7).



TEXTO CON
FALLA DE ORIGEN

Figura 6.7: Diagrama de flujo para la extracción de parámetros a_i

La función **levin**: Calcula los coeficientes a_i del modelo AR de regresión lineal de orden igual a la longitud de la secuencia de entrada.

Uso: $A=levin(Rx);$

Donde:

R_x : Secuencia de autocorrelación a partir de la cual se extraerán los coeficientes a_i .

A: Coeficientes a_i del modelo AR de regresión lineal.

Al final obtenemos los coeficientes del polinomio de orden 16 que modelan a cada uno de los L bloques.

6.6. Módulo de clasificación

El clasificador de señales EEG se encarga de la creación de clases a partir de características de las señales tales como potencia, frecuencia, parámetros a_i , etc; extraídos mediante el módulo de procesamiento de la señal descrito previamente.

Para esta investigación se ha decidido implementar un clasificador de asignación de clases simple; utilizando las funciones de distancia de Chebyshev y distancia espectral RMS a fin de evaluar las similitudes de las características que se pudieran presentar entre distintos bloques de señal.

Para realizar el proceso de clasificación, inicialmente se requirió de la ayuda de un experto, quien visualmente clasificó cada segmento de acuerdo a sus características temporales en: ojos abiertos y ojos cerrados. Con esta clasificación previa, y tomando en cuenta únicamente los bloques correspondientes a ojos cerrados, se extrajeron los vectores de características de correlación, PSD, parámetros a_i y se realizó un promedio ponderado, ecuación(4.4) correspondiente a cada uno de ellos. El promedio obtenido se usó como el vector de características representante de este estado.

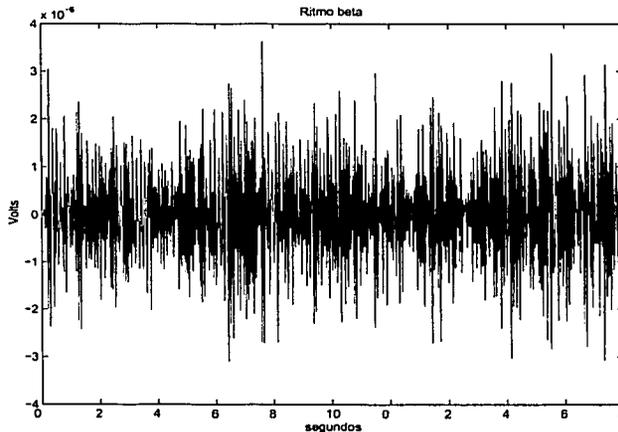
Para cada bloque de señal de 10 segundos, se extrajeron sus vectores de características, los cuales fueron comparados con el vector de características representante mediante una función de distancia y un cierto umbral. Si la distancia obtenida es menor al umbral, entonces se considera que el segmento de señal pertenece a un estado de ojos cerrados, en caso contrario, se asume que el estado pertenece a ojos abiertos. La función de distancia a utilizar dependerá del vector de características ; para el caso de coeficientes de corre-

lación utilizamos la distancia de Chebyshev, mientras que para espectros y coeficientes a_i utilizamos la distancia espectral RMS.

6.7. Simulaciones y pruebas

A continuación presentamos las características extraídas de las señales de EEG mediante los esquemas de procesamiento propuestos. Inicialmente mostramos la caracterización en tiempo, representada por la señal temporal y su función de autocorrelación; seguida de su análisis en frecuencia, que para esta investigación se realizó mediante la distribución espectral de potencia obtenida y su espectrograma con la STFT (de las siglas en inglés Short Time Fourier Transform).

6.7.1. Registro EEG con Ojos Abiertos. Ritmo Beta



TESIS CON
FALLA DE ORIGEN

Figura 6.8: Señal temporal Beta.

La figura 6.8, muestra el registro temporal de la señal EEG con ojos abiertos. Su amplitud promedio es de aproximadamente $6 \mu V_{pp}$ y por el número de cruces por cero de la señal intuitivamente podemos inferir un alto contenido frecuencial.

En la figura 6.9, se observa un rápido decremento de su función de autocorrelación dado por su pendiente; esta característica reafirma la idea de que la señal EEG con ojos abiertos contiene frecuencias altas. Un esbozo de la frecuencia de la señal lo podemos obtener a través del promedio de los intervalos entre las distancias de los cruces por cero. Esta idea se sustenta a partir de que el periodo de la función de autocorrelación de una señal senoidal y el periodo de dicha señal es el mismo. Este razonamiento es útil si nos interesa estimar la frecuencia fundamental de la señal EEG.

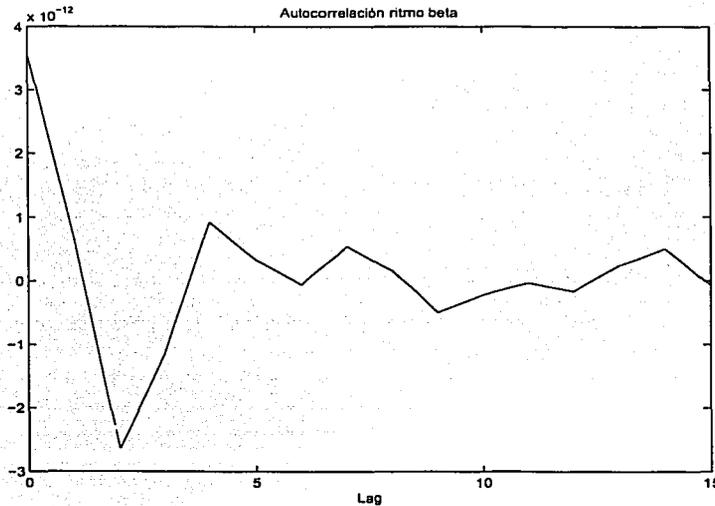
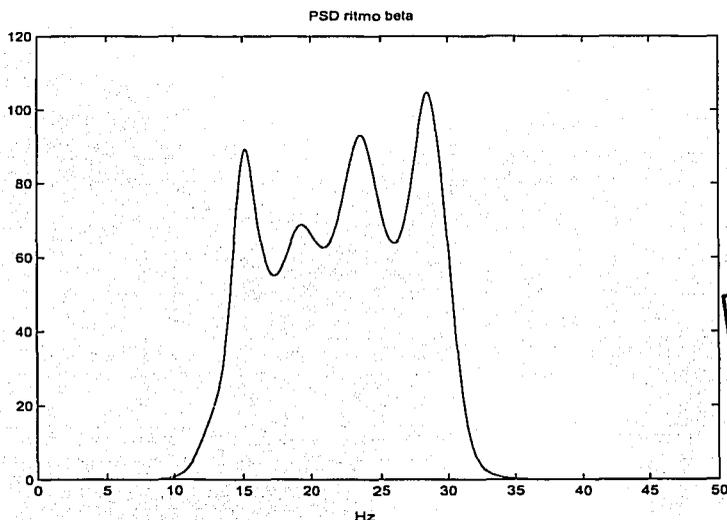


Figura 6.9: Función autocorrelación ritmo Beta

TESIS CON
FALLA DE ORIGEN

Para conocer más sobre las oscilaciones de la señal EEG con ojos abiertos, la trasladamos al dominio de la frecuencia. Podemos observar que su potencia se extiende a partir de los 12 Hz. Los expertos recomiendan filtrar la señal aproximadamente en los 30 hz, por lo que el efecto del filtrado se refleja en la gráfica de la figura 6.10. Este efecto del filtrado no es grave, ya que para los expertos en el área de EEG, frecuencias mayores a 30 Hz son consideradas ruido, o artefactos.



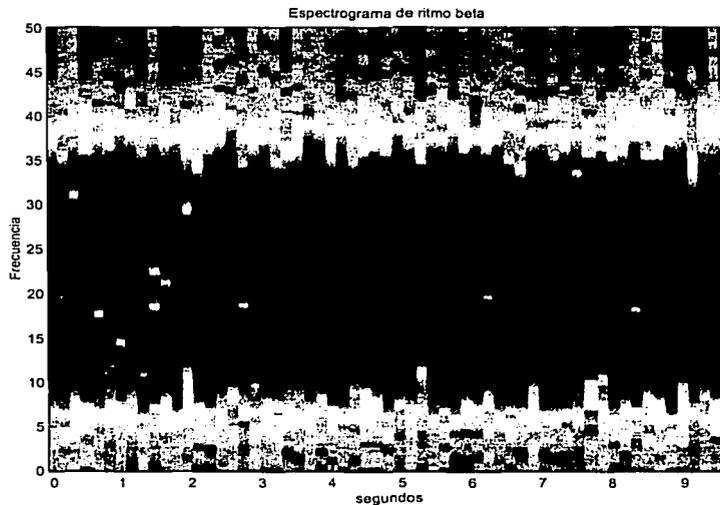
TESIS CON FALLA DE ORIGEN

Figura 6.10: PSD ritmo Beta

La figura 6.10 muestra la PSD de la señal EEG con ojos abiertos extraída a partir de los coeficientes A_i del modelo autoregresivo de orden 16 de la señal. Se observa la existencia de 4 picos, el primero de ellos representa la frecuencia de la señal EEG con ojos cerrados, y los restantes muestran la existencia de superposición de frecuencias debidas, entre otros factores,

al ruido, y sobre todo, el último pico, cercano a los 30 Hz y el de mayor potencia, revela la existencia de una señal de frecuencia y potencia mayor a la actividad EEG, posiblemente se trate de un artefacto muscular, en otras palabras, la señal EEG registrada se encuentra enmascarada con actividad eléctrica muscular que en general es de mayor potencia que la señal EEG.

Adicionalmente presentamos el espectrograma, 6.11, de la señal EEG con ojos abiertos, el cual muestra la variación de potencia de la señal a lo largo del tiempo; donde nuevamente se observa el ancho de banda de la señal, y la aparición de componentes adicionales a la misma.



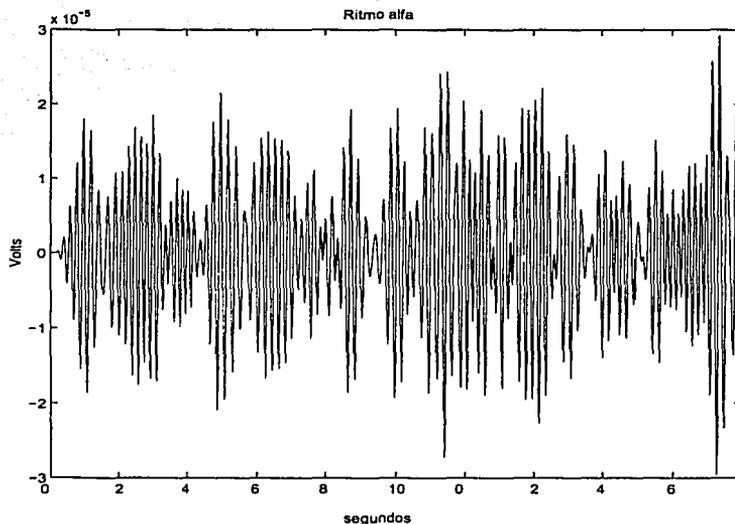
TESIS CON
FALLA DE ORIGEN

Figura 6.11: Espectrograma ritmo Beta

De acuerdo a las características descritas, y comparando los resultados obtenidos con los de la tabla de la sección 1.3.5, la actividad EEG con ojos abiertos se asocia al ritmo Beta.

6.7.2. Registro EEG con Ojos cerrados. Ritmo Alfa

La inhibición de la actividad Beta ocurre después de cerrar los ojos, como puede apreciarse en la figura 6.12, a diferencia del caso ojos abiertos, las señales para ojos cerrados son más lentas y con amplitudes superiores a los $40 \mu V_{pp}$.

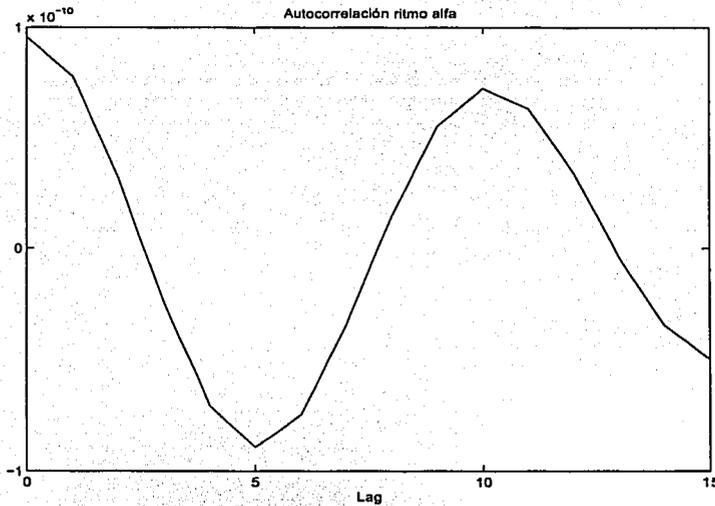


TESIS CON
FALLA DE ORIGEN

Figura 6.12: Señal temporal Alfa

Respecto a su función de autocorrelación, figura 6.13, se observa que existe una menor cantidad de oscilaciones y su pendiente es menos pronunciada respecto a la señal EEG con ojos abiertos, lo que reafirma la idea de que su contenido frecuencial es menor que para el caso de ojos abiertos. Otro

aspecto que resalta a la vista es el hecho de que la curva es mas suave, la correspondiente al caso de ojos abiertos, podríamos suponer en base a su función de autocorrelación, que la señal EEG con ojos cerrados registrada contiene un mínimo de ruido y artefactos, contrario al caso de ojos abiertos.



TESIS CON FALLA DE ORIGEN

Figura 6.13: Función de autocorrelación ritmo Alfa

Continuando con el análisis, la figura 6.14, muestra la PSD de la señal EEG con ojos cerrados, que al igual que para la señal con ojos abiertos, fue extraído a partir de los coeficientes A_i de su modelo autoregresivo de orden 16. En esta figura se observa que su frecuencia fundamental se localiza aproximadamente en los 8 Hz, lo cual confirma que la señal con ojos cerrados es de menor frecuencia y reafirma el hecho de tener menos oscilaciones en su función de autocorrelación respecto a la de la señal Beta.

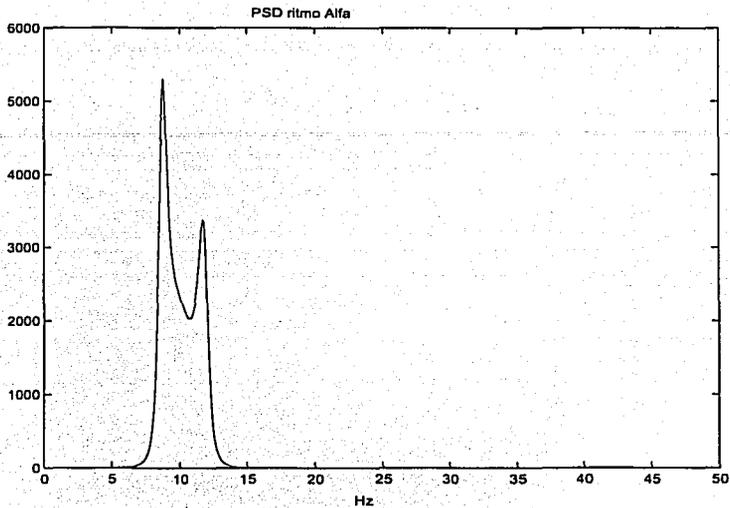
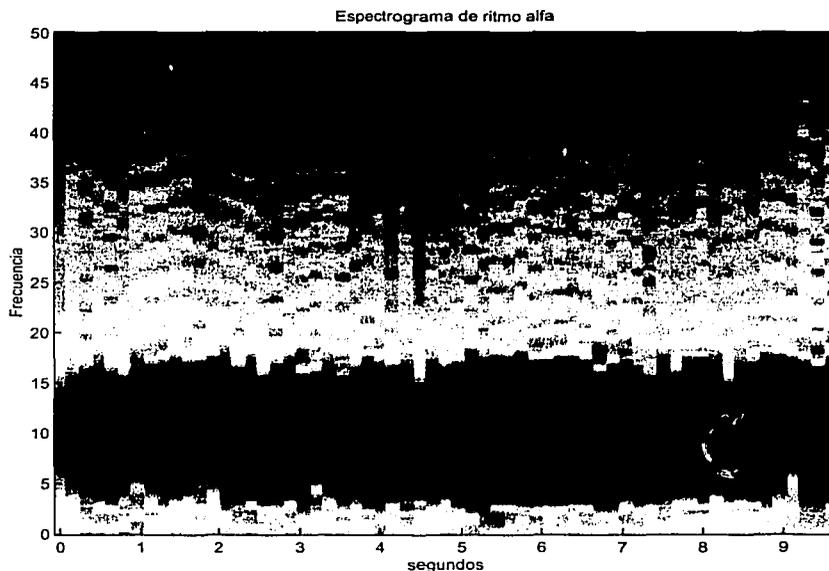


Figura 6.14: PSD del ritmo Alfa

TESIS CON
FALLA DE ORIGEN

Finalmente, en la figura 6.15 presentamos la gráfica del espectrograma de la señal, donde destacamos el hecho de que la potencia de la señal EEG registrada para ojos abiertos se centra alrededor de los 10 Hz. Si recordamos que los valores teóricos de frecuencia de la señal Alfa van de los 8 Hz a los 12 Hz, es fácil ver que la señal EEG con ojos cerrados corresponde a la señal Alfa. Por otro lado, apreciamos que casi no existe potencia fuera de este rango de valores, por lo que inferimos que la señal Alfa registrada no presenta enmascaramiento con artefactos musculares. Esto se debe a que para generar ritmo Alfa, es necesario cerrar los ojos y entrar en un estado de relajación.



TESIS CON
FALLA DE ORIGEN

Figura 6.15: Espectrograma ritmo Alfa

6.7.3. Registro EEG de sueño.

Las técnicas de procesamiento digital de señales, sección 3, usadas en esta investigación, en el ejemplo de nuestra interface, fueron igualmente empleadas para la caracterización de las distintas etapas de sueño².

El registro de sueño fue facilitado por la Dra. Rosa María Campos y la Dra. Matilde Valencia del laboratorio de trastornos del sueño de la facultad de psicología de la UNAM.

²También se les conoce con el nombre de fases de sueño

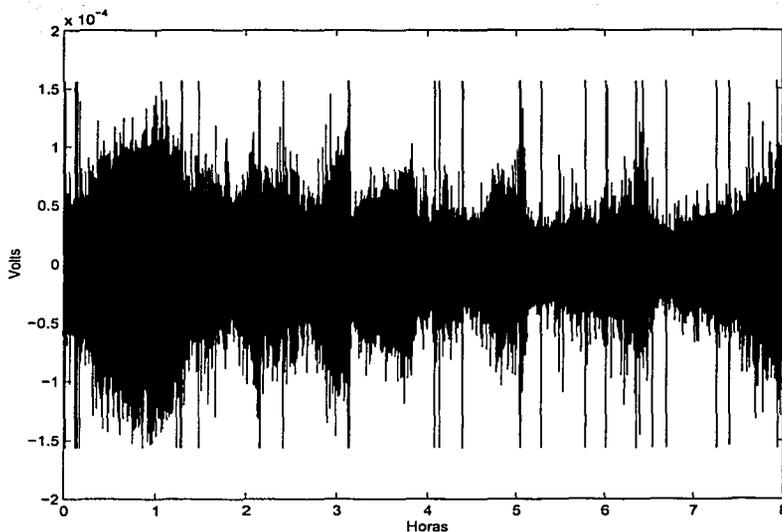
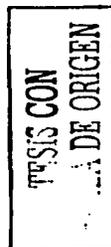


Figura 6.16: Registro temporal de sueño

El registro tiene una duración de 8 horas y pertenece a un individuo normal.

Para este ejemplo se calculó la función de autocorrelación por bloques de 10 segundos. Los coeficientes de autocorrelación fueron clasificados con el algoritmo de asignación de clases simple visto en la sección 4.4. El umbral escogido de manera heurística para la clasificación fue de 6E-11.

En la figura (6.17) se muestra el número de segmentos que representa cada clase. Se obtuvo un total de 173 clases, sin embargo, muchas de ellas no son estadísticamente representativas por contener pocos elementos y pueden ser no consideradas. La figura (6.17) nos puede dar una idea sobre que clases son representativas y cuales no. A simple vista podríamos decir que 4 de ellas son las más representativas y que podrían tratarse de las 4 etapas características del sueño (ver apéndice A). Identificarlas plenamente



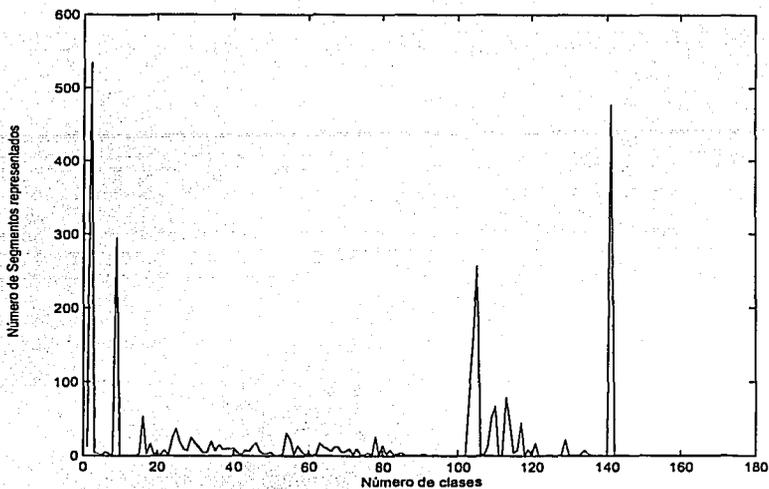


Figura 6.17: Clases representativas

implica retos adicionales como los planteados en [24].

En la figura (6.18) muestra el espectrograma del registro original el cual fue clasificado como se dijo. Con el objeto de comprobar el proceso de clasificación, se obtuvo el espectrograma del registro clasificado, el cual se muestra en la figura (6.19).

TESIS CON
FALLA DE ORIGEN

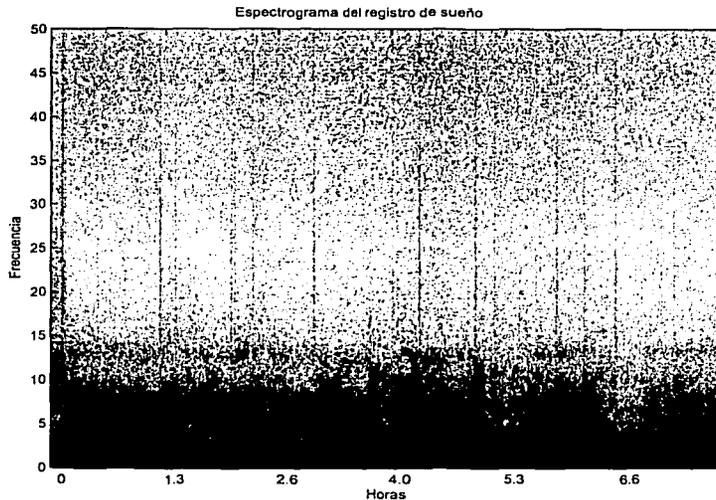


Figura 6.18: Espectrograma del registro de sueño original

Comparando la figura (6.18) con la figura(6.19) encontramos que cualitativamente se parecen, aunque el correspondiente a la figura (6.18) presenta mayor resolución. Esto se debe a que el número de puntos disponibles para el cálculo del espectrograma es significativamente mayor que para el caso del espectrograma clasificado. Lo anterior sugiere que el proceso de clasificación puede verse, si así se quiere, como un proceso de compresión, pues el registro original cuenta con $2.88E^6$ muestras, y después de la clasificación se cuentan con $2.8E^3$ muestras sin modificar significativamente el espectro de la señal.

TESIS CON
FALLA DE ORIGEN

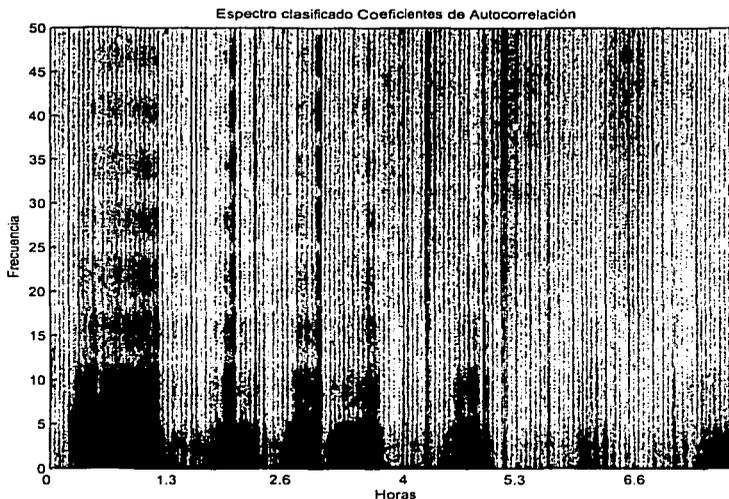


Figura 6.19: Espectrograma del registro de sueño clasificado

Para finalizar con la clasificación de la actividad EEG, presentamos la caracterización de las señales Teta y Delta, las cuales aparecen en las etapas 3 y 4 del sueño. En ambos casos las señales son extremadamente lentas y de amplitudes mayores a los $50\mu V$. Las señales aquí mostradas fueron obtenidas del registro de sueño antes citado. Igual que las anteriores, fueron caracterizadas y clasificadas usando las estrategias de función de autocorrelación, distribución espectral de potencia y espectrograma.

La figura 6.20 pertenece al ritmo Teta; se presenta primeramente su representación temporal, y en segunda instancia su función de autocorrelación.

TESIS CON
 FALLA DE ORIGEN

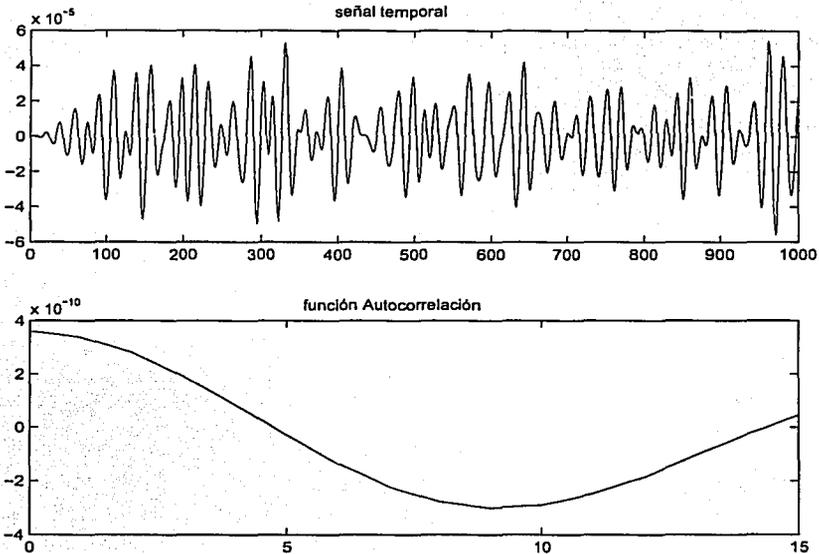


Figura 6.20: Características temporales del ritmo Teta

Podemos apreciar que su forma se asemeja al ritmo Alfa, sin embargo el ritmo Teta es de mayor amplitud, como puede observarse, supera los $80\mu V_{pp}$. A comparación del ritmo Alfa, el ritmo Teta presenta frecuencias mas lentas, lo cual se puede observar en su función de autocorrelación mediante su pendiente y sus cruces por ceros.

Las características del ritmo Teta en el dominio de la frecuencia se pueden observar en la figura 6.21 donde destaca que el rango de frecuencias asociadas al ritmo Teta se localiza en la banda comprendida de lo 3Hz a 7 Hz.

HECHO CON
DE ORIGEN

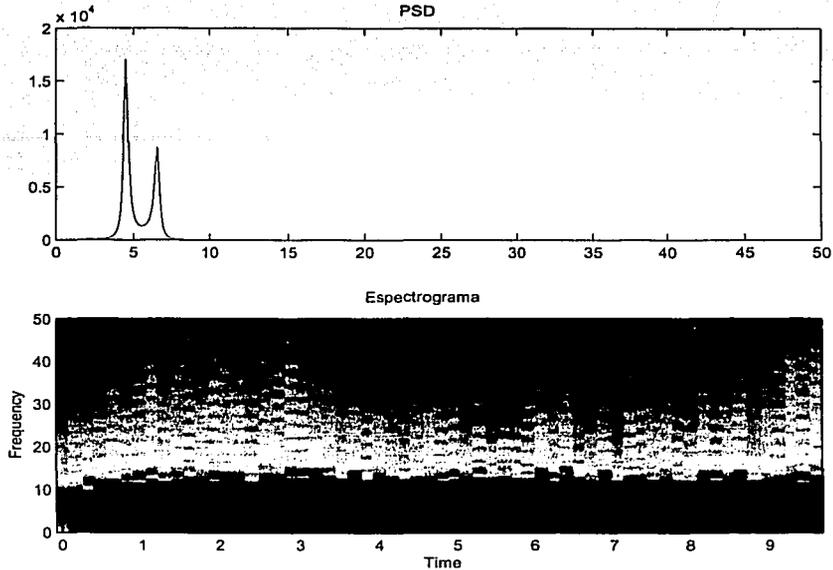


Figura 6.21: Características frecuenciales del ritmo Teta

Por otro lado, en la figura 6.22 tenemos las características temporales del ritmo Delta. Su amplitud es mayor a los $100\mu V$, lo que hace la señal EEG de mayor amplitud. Podemos observar que la función de autocorrelación asociada al ritmo Delta muestra un solo cruce por cero, sin embargo su pendiente en comparación a las anteriores señales es menos pronunciada, lo que nos da la idea de que posee oscilaciones muy lentas.

TESIS CON
FALLA DE ORIGEN

ESTA TESIS NO SALE
DE LA BIBLIOTECA

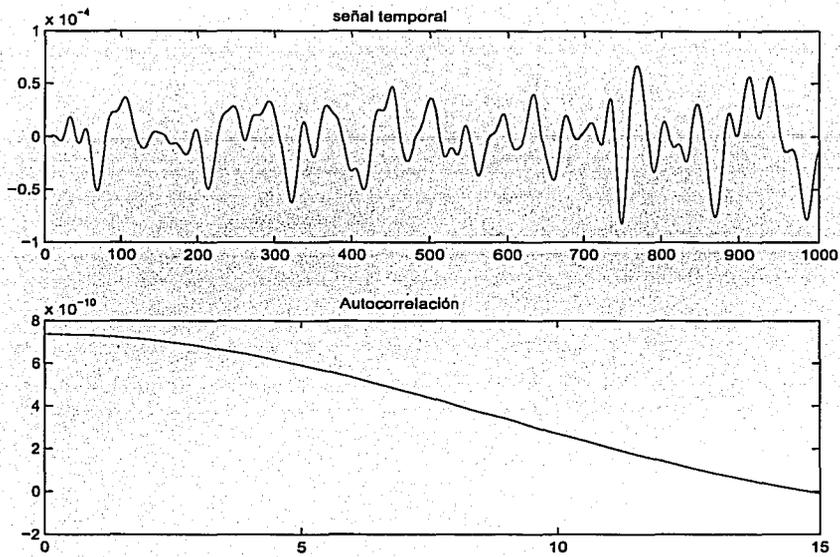


Figura 6.22: Características frecuenciales del ritmo Delta

En realidad, la frecuencia más lenta del cerebro está asociada al ritmo Delta, como podemos darnos cuenta en la figura 6.23, su ancho de banda va de los 0.5 Hz hasta los 4 Hz.

TESIS CON
 DE ORIGEN

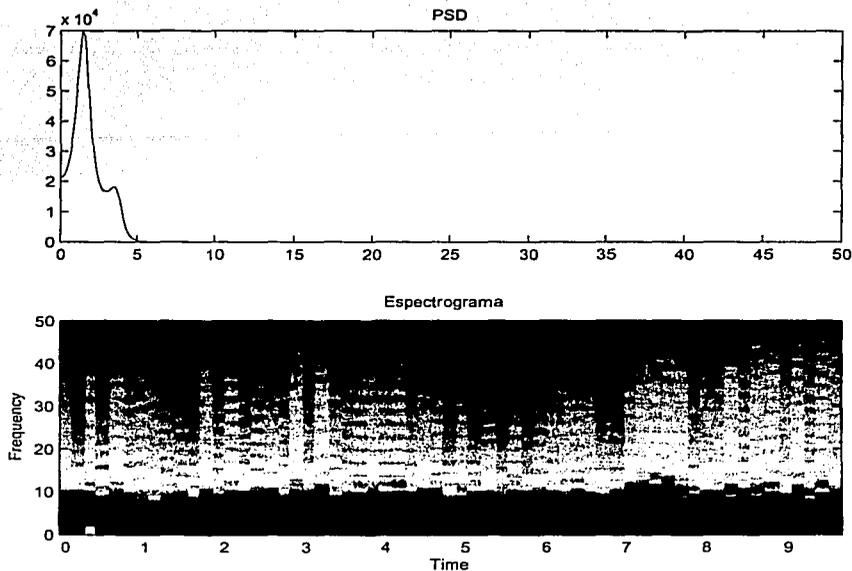


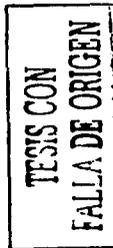
Figura 6.23: Características frecuenciales del ritmo Delta

6.8. Resultados en la clasificación

De acuerdo con la clasificación preliminar hecha por el experto, el registro de EEG contiene 48 segmentos de actividad Alfa y 67 segmentos de actividad Beta.

Con el clasificador visto en la sección 4.4, se obtuvieron los resultados siguientes.

Características empleadas: Coeficientes de autocorrelación



Función de distancia: Distancia de Chebyshev

umbral: 8.4E-12

Alfas clasificadas correctamente 35

Porcentaje de Alfas clasificadas correctamente 72 %

Betas Clasificadas 60

Porcentaje de Betas clasificadas correctamente 89 %

Porcentaje global 78 %

Y por el otro lado obtuvimos:

Características empleadas: PSD

Función de distancia: Distancia Espectral RMS

umbral: 170

Alfas clasificadas correctamente 40

Porcentaje de Alfas clasificadas correctamente 83 %

Betas Clasificadas 63

Porcentaje de Betas clasificadas correctamente 94 %

Porcentaje global 88 %

6.9. Conclusiones

La frecuencia de los distintos estados de EEG se relaciona directamente con la cantidad de conexiones entre neuronas; para el caso de estar concentrado, o tener los ojos abiertos, existe una cantidad mayor de neuronas activas que cuando nos relajamos y tenemos los ojos cerrados o dormimos, [12]. Por otro lado, la potencia de la señal mantiene una relación inversa con la cantidad de neuronas activas, ya que para el caso de estado de relajación o sueño, la potencia de la señal es mayor que en el caso de concentración

y vigilia. Estas características pueden observarse a través de nuestro estudio, sin embargo, las señales obtenidas en el laboratorio presentan algunas discrepancias con sus características teóricas; ejemplo de esto lo constituye un ritmo Beta de amplitud mayor a los $5\mu V$, que al compararlo en potencia, puede en ocasiones confundirse con el ritmo Alfa y resultar en una mala clasificación del estado. Esta discrepancia en amplitud, se debe en mi caso, a la ingesta de medicamentos, lo que constituye una variable más a controlar en la implementación de nuestra BCI. Otro factor que afecta al registro EEG, sobre todo en vigilia, es el enmascaramiento de la señal con el ruido y con los artefactos, sobre todo de músculo, ya que al estar despierto, el tono muscular no está relajado, y al ser señales de mayor potencia que la actividad EEG, ésta se enmascara. Lo anterior no es tan grave para los registros de sueño, en donde el tono muscular es relajado y la potencia de la actividad cerebral aumenta.

Por otro lado, otra discrepancia encontrada en las señales registradas se refiere a su frecuencia; en ocasiones, cuando una persona sufre de somnolencia o algún otro trastorno afín, es común que predominen ondas lentas durante un registro de vigilia, y la actividad rápida característica de un estado ojos abiertos sea escasa.

A pesar de éstas discrepancias, fue posible extraer características excluyentes de cada una de las señales de EEG.

Conclusiones y perspectivas

El mayor atractivo del uso de Herramientas DSP para caracterizar señales EEG radica en que no necesitamos volvernos expertos en el fenómeno para poder analizar y extraer información útil en la toma de decisiones asistida por computadora. En esta investigación analizamos la señal EEG mediante el uso de la función de autocorrelación, modelamos la señal como un proceso autoregresivo, clasificamos sus coeficientes e hicimos uso de la PSD para representar la señal en el dominio de la frecuencia; adicionalmente, obtuvimos el espectrograma de la señal para ilustrar su potencia a lo largo del tiempo.

Para un umbral de $8.4E-12$, se obtuvo un 78% de aciertos en la clasificación de características mediante la función de autocorrelación y distancia de Chebyshev; mientras que para un umbral de 170 (umbral obtenido mediante experimentación), se obtuvo un 88% de acierto en la clasificación de características extraídas con la PSD. Por lo que se consiguió una mejora del 10% mediante el uso de características frecuenciales de la señal EEG, sobre aquellas dadas por la correlación. Es importante notar que estos valores de clasificación no solo dependen de las características empleadas, sino que además dependen de los umbrales seleccionados y de la función de distancia utilizada en el clasificador. Los valores que aquí reportamos fueron los mejores resultados obtenidos.

Aunque con un 10% menor en el desempeño de la clasificación, pensamos que la estrategia de usar funciones de autocorrelación para caracterizar señales de EEG es recomendable debido no solo a su simplicidad, sino también, como observamos en este trabajo, es posible extraer información de la potencia de la señal a través del coeficiente cero, información de la "frecuencia fundamental" de la señal mediante sus cruces por cero, o podemos darnos una idea de que tan rápida o lenta es la frecuencia de la señal median-

te su pendiente sin necesidad de aumentar la complejidad de cálculo. Esto resulta importante si se piensa en clasificación en tiempo real de la señal EEG.

Por otro lado, si deseamos una mejor precisión en cuanto a las características frecuenciales de la señal EEG, nos conviene hacer uso de herramientas que representen a la señal en el dominio de la frecuencia; tal es el caso de la obtención de la PSD, que en este trabajo, se obtuvo mediante los coeficientes a_i de su modelo autoregresivo de orden 16. La obtención de la PSD a través del modelado de la señal, hace más pesado el cálculo, porque primero tenemos que modelar a la señal y después obtener el inverso de la transformada de Fourier de sus coeficientes. Esto si bien es caro, nos permite obtener curvas más suaves y mejor resolución de la PSD.

Otra estrategia para la caracterización de las señales EEG, que no se realizó en esta investigación y que se plantea como trabajo futuro resulta de implementar algoritmos para la extracción de firmas espectrales de los espectrogramas de la señal EEG en la búsqueda de patrones asociados a cada estado.

Aún queda mucho por hacer en el desarrollo de BCIs, hoy en día se sigue trabajando y desarrollando nuevas estrategias de procesamiento y clasificación de señales EEG con el fin de obtener interfaces más eficientes; y aunque éstas estrategias aumentan en grado de complejidad, la mayoría de ellas están basadas en los principios y herramientas básicas del procesamiento digital de señales que utilizamos para esta investigación.

No obstante que técnicamente y fisiológicamente es posible el desarrollo de una interfaz de este tipo, se deben solventar diversas cuestiones que hasta la fecha hacen de las BCIs sistemas imprácticos. Por ejemplo, en lo referente a la adquisición de la señal, se hace patente la necesidad de traer colocados gran cantidad de electrodos y cables en la superficie del cráneo, lo que a parte de resultar incómodo para el usuario, se corre el riesgo de sufrir alguna desconexión o movimiento de electrodos, y con ello un mal funcionamiento de la interfaz. En la parte del hardware, hoy en día se pueden solventar problemas de dimensiones y peso, ya que el software puede ser ejecutado en un microcontrolador, sin embargo, el estado actual de las BCIs, sigue en desarrollo, por lo cual el hardware utilizado aún es grande y además costoso.

Otra razón que hace ineficiente a estas interfaces es que hasta la fecha las BCIs siguen siendo de tipo individual. Aún no se cuenta con una interface que pueda ser usada por cualquier persona, lo cual se debe a que no todas las personas son capaces de modificar su actividad cerebral a voluntad. Debido a ello, las BCIs que han tenido mas éxito son aquéllas que involucran fenómenos de cambio en la actividad cerebral relacionados con ciertas actividades, por ejemplo, el abrir y cerrar los ojos, o el concentrarse en alguna actividad mental como imaginar que producimos un movimiento con el cuerpo; y aún bajo estos esquemas, es necesario afrontar las discrepancias existentes entre las señales de cada individuo.

Bibliografía

- [1] Rogelio Alcántara Silva, *Apuntes de procesamiento de señales aleatorias*, DEEFI-UNAM, 2002.
- [2] R. Aston, *Principles of biomedical instrumentation and measurement*, Merrill publishing, Estados Unidos de América, 1990.
- [3] P. Boaz, *A course in digital signal processing*, John Wiley and sons, Inc, Toronto, 1997.
- [4] J. Brualla and M. Romero, *P300 y procesamiento de información auditiva durante el sueño*, NEUROL (1999), no. 29, 503-507.
- [5] D. Budimir and B. Stephen, *A portable eeg recording system*, Tech. report, Department of Electrical Engineering, Division of Neurosurgery, University of California, 1989.
- [6] P.J. Cilliers and A.J.W. Van Der Kouwe, *A vep-based computer interface for c2-quadruplegics*, 1993, IEEE Conference on Electronic Devices for the Disabled Beyond 2000.
- [7] R. Coughlin and F. Driscoll, *Amplificadores operacionales y circuitos integrados lineales*, 5a ed., Prentice Hall, México, 1999.
- [8] R.A. Drake, *Processing persuasive arguments: 2. discounting of truth and relevance as a function of agreement and manipulated activation asymetry*, Journal of Research in Personality (1993), no. 27, 184-196.
- [9] L.A. Farwell and E. Donchin, *Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials*, Electroencephalography and Clinical Neurophysiology (1988), no. 70, 510-523.

- [10] T. Fays and J. Knott, *Fundamentals of eeg technology basic concepts and methods*, vol. 1, Raven Press, New York., 1983.
- [11] A. Gray and J. Markel, *Distance measures for speech processing*, IEEE Transactions on Acustics, Speech, and Signal Processing (1976), no. 5.
- [12] A. Guyton and J. Hall, *Tratado de fisiología médica*, Mac Graw Hill - Interamericana, México, 1997.
- [13] A. K. Jain and M.Ñ. Murty, *Data clustering: a review*, ACM Computing Surveys (1999), no. 3, 264-323.
- [14] A.K. Jain and R.C. Dubes, *Algorithms for clustering data*, Prentice Hall, 1988.
- [15] K. Kooi, *Fundamentos de electroencefalografía*, Ediciones Toray, Barcelona, 1975.
- [16] J. Lehtonen, *Eeg-based brain computer interfaces*, Helsinki University of Technology, Mayo 2002.
- [17] S. Manson and G. Birch, *A general framework for brain - computer interface desing*, IEEE TRansactions on Neural Systems and Rehabilitation Engineering (2003), no. 1, 70-85.
- [18] G.R. McMillan and G.L. Calhoun, *Direct brain interface utilizing self regulation of steady state visual evoked response*, 1995, Proc. RESNA, annual conference, Vancouver Canada.
- [19] J. Muñoz, C. Jiménez, *Potenciales evocados ii. potenciales exógenos*, Revista Mexicana de Ingeniería biomédica (2002), no. 1.
- [20] E. Niedermeyer and F. Lopes da Silva, *Electroencephalography. basic principles, clinical applications and related fields*, 2a ed., Urban and Schwarzenberg, Munich, 1987.
- [21] R. Pallás, *Adquisición y distribución de señales*, Marcombo Boixarcu editores, Barcelona, 1993.
- [22] J. Proakis and D. Manolakis, *Tratamiento digital de señales.*, 3a ed., Prentice Hall, Madrid, 1998.

- [23] M. Rangayyan, *Biomedical signal analysis. a case study approach*, John Wiley and sons Inc - IEEE press, USA, 2002.
- [24] A. Rechtschaffen and A. Kales, *A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects*, Brain information service - Brain research institute, Los Angeles California, 1963.
- [25] E.E. Sutter, *The brain response interface: communication through visually induced electrical brain responses*, Journal of Microcomputer Applications (1992), no. 15, 31-45.
- [26] B. Sutton, *Evoked potential correlates of stimulus uncertainty*, Science (1965), no. 155, 1187-1188.
- [27] J. Wolpaw and et al, *Brain-computer interface technology: A review of the first international meeting.*, IEEE Transactions on Rehabilitation Engineering (2000), no. 2, 164 - 173.
- [28] J.R. Wolpaw and D.J. McFarland, *An eeg-based brain-computer interface for cursor control*, Electroencephalography and Clinical Neurophysiology (1991), no. 78, 252-259.
- [29] Claudia Zepeda Cortés, *Sistema de clasificación de señales eeg utilizando el ambiente de programación visual khoros*, Benemérita Universidad de Puebla, Junio 1995.

Apéndice A

El Sueño

A.1. Introducción

El sueño es una actividad que ocupa una tercera parte de la actividad humana, [24]. Antiguamente los griegos asociaban el sueño con la muerte. Hypnos, dios del sueño, era hijo de Erebo (una región tenebrosa que se hallaba bajo la tierra aunque por encima del Infierno) y hermano de Thanatos, dios de la muerte. Los griegos consideraban que al dormir nuestra alma se adentraba en las tinieblas de la muerte, y al despertar, resucitábamos. Por otro lado, los romanos consideraban el sueño como restaurador de la esperanza, el descanso del cuerpo fatigado, la paz del alma. A lo largo de la historia de este fenómeno siempre ha despertado curiosidad por el misterio que éste encierra.

Se han dado diferentes explicaciones del porqué dormimos; se cree que el sueño cumple con una función restauradora, se considera como un estado que le permite al organismo conservar energía y como una respuesta adaptativa. Sin embargo todavía no ha sido posible determinar con certeza la verdadera función del sueño,[12].

Durante el período de sueño, en nuestro organismo acontecen una serie de cambios fisiológicos, desde variaciones en el funcionamiento cerebral, en el sistema muscular, o en la respiración, hasta cambios en el sistema genital. En 1968, y a partir de las observaciones realizadas en algunos de estos parámetros, A. Rechtschaffen y A. Kales publicaron un manual de clasificación del

sueño en diferentes etapas, clasificación que hoy en día sigue aún vigente (A Manual of Standardized Terminology, Techniques and Scoring System for Sleep Stages of Human Subjects), [24]. De acuerdo a esta clasificación, el sueño se subdivide en 2 grandes etapas: MOR y NMOR (con y sin movimientos oculares rápidos). A su vez, la etapa NMOR se subdivide según la profundidad del sueño (de menor a mayor) en fase 1, fase 2, fase 3 y fase 4.

A.2. Fases del sueño

Podemos ver al sueño como una serie de fases relacionadas con actividad cerebral específica durante un período de tiempo. En general un ciclo de sueño comprende 90 minutos, en los cuales saltamos de una fase a otra. De acuerdo a la clasificación hecha en [24], las etapas del sueño son las siguientes:

A.2.1. Fase 1

El sueño comienza con la fase 1, también conocida como somnolencia, la cual es una etapa de transición entre vigilia y sueño; se caracteriza por una actividad cerebral de bajo voltaje en el hipocampo y la región cortical. Las frecuencias típicas para esta fase van de 2 a 7 Hz, mientras que la amplitud de sus señales oscilan entre los 50 y 75 μ V.

Durante el sueño nocturno, la duración de la fase uno tiende a ser relativamente corta, entre 1 a 7 minutos y se presenta generalmente posterior a un cambio de posición al dormir. Conforme la fase uno avanza y se acerca a la fase 2 del sueño, las frecuencias comienzan a ser del orden de los 15 a 20 Hz. y la amplitud puede llegar a ser hasta de 200 μ V.

La transición entre el bajo voltaje de la vigilia y la etapa uno, se caracteriza por una generalizada disminución en la frecuencia del EEG. El ritmo Alfa disminuye en amplitud y voltaje. Se considera que un individuo ha entrado a la etapa uno del sueño cuando la actividad Alfa combinada con la actividad de bajo voltaje decrece en un 50% del total de la época registrada.

A.2.2. Fase 2

Conforme el sueño avanza inicia la fase 2, la cual se caracteriza por la aparición de los llamados usos de sueño (ondas de 0.5 a 2 segundos de ac-

tividad Beta con 12 a 14 ciclos por segundo), complejos K (ondas bifásicas de gran amplitud) y la desaparición de señales de alto voltaje; en esta etapa pueden aparecer movimientos oculares de manera escasa y el tono muscular es menor que en la fase 1. La duración aproximada de esta fase va de los 10 a los 25 minutos. En esta fase aparece un bloqueo sensorial a nivel del tálamo, lo que provoca la desconexión del entorno y la posibilidad de avanzar en etapas más profundas del sueño.

A.2.3. Fase 3

En esta fase, la desconexión sensorial aumenta, si llegáramos a despertar durante esta fase nos sentiríamos confusos y desorientados.

Se considera que un sujeto ha entrado en la fase 3 del sueño cuando alrededor del 20% y no más del 50% del registro de EEG se compone por ondas con frecuencia de 2 Hz o menores, y amplitudes del orden de 75 μV pico a pico, correspondientes al ritmo Delta. En la fase 3 los usos de sueño pueden o no aparecer. El tono muscular es más reducido que en la fase 2 y no hay presencia de movimientos oculares. Fase 4

La fase 4 se considera como la fase más profunda del sueño, se dice que en esta fase se lleva a cabo la restauración física y psíquica de mayor importancia del organismo; así mismo, es durante este periodo donde el sonambulismo y los terrores nocturnos se presentan.

La actividad cerebral durante ésta fase se caracteriza por presentar ondas de 2 Hz o de menor frecuencia, con amplitudes mayores a los 75 μV pico a pico en más del 50% de la época¹, aunque raramente más de la mitad de la época contiene amplitudes altas, ya que en esta fase pueden llegar a presentarse intervalos de pocos segundos de duración donde las señales son de frecuencia alta y poca amplitud.

Aunque la fase 4 no es la fase donde aparecen los sueños, es posible que éstos existan en forma de imágenes, luces o figuras incoherentes.

A.2.4. Fase MOR

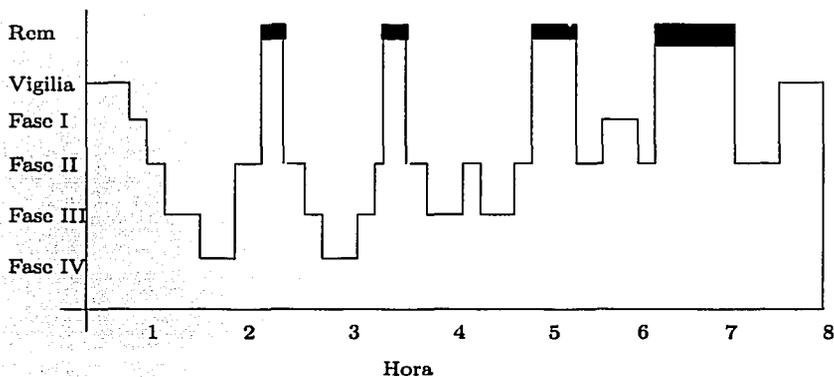
Sin duda la fase más extraña del ciclo de sueño es la conocida como fase MOR; acrónimo de Movimientos Oculares Rápidos. Esta fase es un período normal en todo ser humano que se relaciona con los sueños. Durante la fase

¹30 segundos de registro de sueño

MOR, el tono muscular disminuye, sin embargo, a pesar de la extrema inhibición de los músculos se llegan a producir movimientos musculares irregulares, sobre todo y en especial, los movimientos oculares, de donde esta fase toma su nombre. En ésta fase, la frecuencia cardiaca y respiratoria se vuelven irregulares; también existe mucha actividad cerebral, lo que hace que en el registro de EEG aparezcan señales mayoritariamente Teta de baja amplitud con ráfagas de actividad Beta parecidas a las obtenidas durante la vigilia. Los investigadores del sueño han llamado también a esta fase como sueño paradójico, pues resulta una paradoja que a pesar de la intensa actividad cerebral un sujeto permanezca dormido.

A.3. Hipnograma

Un hipnograma puede concebirse como la representación gráfica de la actividad bioeléctrica del cerebro durante el sueño en un eje temporal (fig. 4). Un hipnograma registra la evolución de las distintas fases del sueño por las que un individuo cruza.



TESIS CON
 FALLA DE ORIGEN

Figura A.1: Ejemplo de hipnograma normal

A.4. Higiene de sueño

El sueño es la actividad más importante del ser humano, en ella invertimos la tercera parte de nuestra vida. Hoy en día el sueño es un proceso natural envuelto de misterio, no se sabe a ciencia cierta para qué dormimos o para que soñamos, sin embargo queda demostrado que durante el sueño, la actividad eléctrica del cerebro es totalmente diferente a aquella presentada en estado de vigilia y aunque no se sabe la finalidad de estos cambios, es muy claro que cualquier comportamiento anormal se traduce en trastornos físicos y/o psicológicos. El estudio del sueño a través de la polisomnografía ha demostrado ser eficaz en el diagnóstico de patologías graves como epilepsia, tumores cerebrales, trastornos respiratorios, insomnio, somnolencia y muchos otros padecimientos.

Dada la importancia que ocupa el sueño en nuestras vidas, es muy importante contar con una buena higiene del sueño, para ello es recomendable practicar las siguientes medidas:

- Evitar productos como el café, el refresco de cola, los cigarros u otra sustancia estimulante antes de dormir
- Hacer ejercicio diariamente de preferencia por las mañanas
- Tomar un baño caliente por lo menos 30 minutos antes de ir a dormir
- Acostarse y levantarse en un horario regular incluyendo fines de semana
- Evitar la ingesta de alimentos en abundancia por lo menos 3 horas antes de ir a acostarse
- No acostarse en la cama si no se va a dormir, pasar mucho tiempo en la cama puede alterar el hábito del dormir
- La habitación debe estar libre de luces y ruidos
- Evitar ver televisión antes de dormir
- Si no se puede conciliar el sueño en un lapso de 30 minutos, se recomienda practicar alguna actividad como el leer

Apéndice B

Código en MATLAB

A continuación se presenta el código de las funciones utilizadas durante el presente trabajo. Todas las funciones implementadas fueron programadas en MATLAB, y a pesar de que la mayoría de ellas ya forman parte del conjunto de librerías de MATLAB, fueron programadas de nueva cuenta para efectos pedagógicos.

B.1. Autocorrelación sesgada

```
function Rxx=acorrb(x,coef)
N=length(x);
for m=1:coef,
suma=0;
for n=1:N-m,
suma=x(n)*x(n+m-1)+suma;
end %for n
Rxx(m)=1/N*suma;
end %for m
```

B.2. myfft

```
function y=myfft(x,n)
%Calcula la transformada rapida de Fourier mediante decimacion
```

```

%en el tiempo de una secuencia x de longitud n. %donde n debe ser
potencia de 2
if n==1,
y=x(1);
else
wn=exp(-i*2*pi/n);
w=1;
pares=x(2:2:n);
impares=x(1:2:n);
ypar=myfft(pares,n/2);
yimpar=myfft(impares,n/2);
for k=1:n/2,
y(k)=ypar(k)+w*yimpar(k);
y(k+n/2)=ypar(k)-w*yimpar(k);
w=wn*w;
end
end

```

B.3. Periodograma

```

function Sx=SxP(x)
%Estima la densidad espectral de potencia de una señal x
%mediante el periodograma
x=adjpot2(x);
N=length(x);
Sx=fft(x,N);
Sx=Sx.*conj(Sx);

```

B.4. Levinson Durbin

```

function a=levin(Rx)
xx=1; a(1,1) = -Rx(2)/Rx(1);
k(xx,1) = -Rx(2)/Rx(1); E(xx,1) = Rx(1)+a(1,1)*Rx(2);
P=length(Rx);
for m =2:P-1,
sum(m) = 0;

```



```

for k1 = 1:m-1,
sum(m) = a(m-1,k1).*Rx(m-k1+1)+sum(m);
end;
Deltaf(xx,m-1) = Rx(m+1) + sum(m);
k(xx,m)=-(Deltaf(xx,m-1))./(E(xx,m-1));
a(m,m) = k(xx,m);
for k1 = 1:m-1,
a(m,k1) = a(m-1,k1)+ k(xx,m).*a(m-1,m-k1);
end;
E(xx,m)= (1 -( k(xx,m).*k(xx,m))).*(E(xx,m-1));
end;
xx = xx + 1;
end; a(2:16)=a(15,1:15); a(1)=1;

```

B.5. Respuesta en frecuencia

```

function [Hz, absH]=Hdcw(a,b,K)
m=0:length(b)-1;
l=0:length(a)-1;
k=0:K-1;
T=1/100;
w=2*pi*k/K;
num=b*exp(-j*m'*w);
den=a*exp(-j*l'*w);
H=num./den;
absH=abs(H);
Hz=k*(1/(K*T));
plot(Hz(1:K/2),absH(1:K/2));
xlabel('Hz');

```

B.6. Distancia de Chebyshev

```

function D=Dcheby(Rxi,Rxj)
D=max(abs(Rxi-Rxj));

```

B.7. Distancia espectral RMS

```
function [d,V]=dcspc(x,z) %distancia espectral
V=log(x)-log(z);
d=sum( V. 2);
```

B.8. Clasificador

```
H=6E-11; %umbral de decision (2 clases)
%H=170; %para la distancia espectral
features='features.dat';
clases='clases.dat';
fpclas=fopen(clases,'wb+');
fpfea=fopen(features,'rb');
fseek(fpfea,0,1);
FDAfea=ftell(fpfea); %leo el tamaño del archivo feature
fseek(fpfea,0,-1);
f=fread(fpfea,16,'double');
fwrite(fpclas,f,'double'); %el primer conjunto de características %forma la
primera clase
posfea=ftell(fpfea);
FDAclas=ftell(fpclas); fseek(fpclas,0,1);
FDAclas=ftell(fpclas);
fseek(fpclas,0,-1);
posclas=ftell(fpclas);
Np(1)=1; %la clase 1 representa Np segmentos
nclases=1;
while posfea =FDAfea, %para el primer conjunto de feature hasta el ultimo
f=fread(fpfea,16,'double');
j=1; %iniciamos el contador de clases
while posclas =FDAclas; %para la primera clase hasta la ultima
c=fread(fpclas,16,'double');
posclas=ftell(fpclas);
dist(j)=Dcheby(f,c); %distancia del conjunto a la clase j
%dist(j)=dcspc(f,c); %para el caso de PSD
j=j+1;
end
```

```

[dmin,J]=min(dist);%la clase J tiene distancia minima al conjunto
if dmin<H,%si la distancia entre clase y conjunto es menor a un umbral
entonces pertenece a la clase J
%modificamos el centro de gravedad de la clase
fseek(fpclas,128*(J-1),-1);%el vector de características ocupa 16*64bits
%nos posicionamos en la clase J
c=fread(fpclas,16,'double');
c=1/(Np(J)+1)*(Np(J)*c+f);
Np(J)=Np(J)+1;
fseek(fpclas,128*(J-1),-1);
fwrite(fpclas,c,'double');
else
%el conjunto de características analizado forma su propia clase
nclases=nclases+1;
Np(nclases)=1;
fseek(fpclas,0,1);
fwrite(fpclas,f,'double');
FDAclas=ftell(fpclas);
end
posclas=fseek(fpclas,0,-1);%regresamos el apuntador de clases al inicio
posfea=ftell(fpfea);%actualizamos la posición del archivo de features
end

```

B.9. artifact

```

fp=fopen('ecg2.dat','rb');
pos=16000;
fseek(fp,pos,-1);
y=fread(fp,int16');
y=fiscaliza(y);
ymedia=mean(y);
ystd=std(y);
ini=0;
for i=1:length(y),
if (y(i)>fix(ymedia-ystd) & y(i)<fix(ymedia+ystd)),
ini=ini+1;

```

```

else
if ini==0,
y(i-ini:i-1)=y(i-2*ini:i-1);
end
ini=0;
end
end;
fp2=fopen('ecg.dat','wb');
y=limpia(y);
fwrite(fp2,y,'double');
fclose all;

```

B.10. limpia

```

function y=limpia(x)
fs=100;%frecuencia de muestreo
T=1/fs;%periodo de muestreo
fn=fs/2;%frecuencia de Nyquist
fmbeta=[8 30]/fn;
%frecuencia normalizada
[Bbeta,Abeta]=butter(8,fmbeta);
%filtro butterwort de 5 orden
[Hbeta,wT]=freqz(Bbeta,Abeta,512);
hz= wT/(2*pi*T);
y=filter(Bbeta, Abeta,x);

```

B.11. EEG sintética

B.11.1. Señal Alfa

```

y=function Alfa(N)
fs=100;%frecuencia de muestreo
T=1/fs;%periodo de muestreo
fn=fs/2;%frecuencia de Nyquist
fnAlfa=[8 13]/fn;%frecuencia Alfa normalizada
[BAlfa, AAlfa]= butter(5,fnAlfa);%filtro butterwort de 5 orden

```

```
x=wgn(1,N,-84);  
y=filter(BAlfa, AAlfa,x);
```

B.11.2. Señal Beta

```
function y=Beta(N)  
fs=100; %frecuencia de muestreo  
T=1/fs; %periodo de muestreo  
fn=fs/2; %frecuencia de Nyquist  
fnBeta=[13 30]/fn; %frecuencia Beta normalizada  
[BBeta,ABeta]=butter(5,fnBeta); %filtro butterwort de 5 orden  
x=wgn(1,N,-94);  
y=filter(BBeta, ABeta,x);
```

B.11.3. Señal Teta

```
function y=Teta(N)  
fs=100; %frecuencia de muestreo  
T=1/fs; %periodo de muestreo fn=fs/2; %frecuencia de Nyquist  
fnTeta=[3.5 8]/fn; %frecuencia Teta normalizada  
[BTeta,ATeta]=butter(5,fnTeta); %filtro butterwort de 5 orden  
x=wgn(1,N,-96);  
y=filter(BTeta, ATeta,x);
```

B.11.4. Señal Delta

```
function y=Delta(N)  
fs=100; %frecuencia de muestreo  
T=1/fs; %periodo de muestreo  
fn=fs/2; %frecuencia de Nyquist  
fnDelta=3.5/fn; %frecuencia Delta normalizada  
[BDelta,ADelta]=butter(5,fnDelta); %filtro butterwort de 5 orden  
x=wgn(1,N,-86);  
y=filter(BDelta, ADelta,x);
```

Apéndice C

Algoritmo de Levinson Durbin

El algoritmo de Levinson es una forma rápida, fácil y elegante de obtener los coeficientes a_k de las ecuaciones normales de Yule - Walker, fue propuesto por Levinson en 1947 en un trabajo sobre el problema de Predicción de Wiener. Años después, en 1960, Durbin lo mejora. Ahora conocido como algoritmo de Levinson - Durbin, es uno de los algoritmos más útiles en aplicaciones del procesamiento de señales como: estimación del espectro de una señal, codificación de voz, filtrado, etc. En este trabajo se emplea el algoritmo de Levinson - Durbin para la obtención de los coeficientes a_i del modelo AR de predicción lineal, aprovechando que la matriz resultante es una matriz de tipo Toeplitz [22]. El algoritmo es el siguiente:

1. $S_0 = R_x[0]$
2. $i = 0$
- 3.

$$\rho_{i+1} = \frac{R_x[i+1] + \sum_{m=0}^i a_{i,m} R_x[i+1-m]}{S_i}$$

4. $S_{i+1} = S_i (1 - \rho_{i+1}^2)$
5. $a_{i+1,m} = a_{i,m} - \rho_{i+1} a_{i,i+1-m} \quad 1 \leq m \leq i$
6. $a_{i+1,i+1} = -\rho_{i+1}$
7. $i = i + 1$

8. Repetir mientras $i < p$