

Universidad Autónoma de Querétaro
Facultad de Ingeniería
Campus Aeropuerto



**Metodología basada en la descomposición de modos variacional
para la detección de pacientes con predisposición al alcoholismo
empleando señales EEG**

TESIS

Que como parte de los requisitos para obtener el título de
Ingeniero Biomédico
línea terminal en
Bioseñales y Bioinstrumentación

Presenta:

Miguel Morales Anaya

Dirigida por:

Dr. Juan Pablo Amézquita Sánchez

Santiago de Querétaro, Qro, Noviembre del 2022



Dirección General de Bibliotecas y Servicios Digitales
de Información



Metodología basada en la descomposición de modos
variacional para la detección de pacientes con
predisposición al alcoholismo empleando señales
EEG

por

Miguel Morales Anaya

se distribuye bajo una [Licencia Creative Commons
Atribución-NoComercial-SinDerivadas 4.0
Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/).

Clave RI: IGLIN-262939



Universidad Autónoma de Querétaro



Facultad de Ingeniería

Ingeniería Biomédica

Metodología basada en la descomposición de modos variacional para la detección de pacientes con predisposición a alcoholismo empleando señales EEG.

Tesis

Que como parte de los requisitos para obtener el título de Ingeniero Biomédico.


Presenta:

Miguel Morales Anaya

Dirigido por:

Dr. Juan Pablo Amézquita Sánchez

Dr. Juan Pablo Amézquita Sánchez
Presidente


Firma

Dr. Carlos Andrés Pérez Ramírez
Secretario


Firma

Dr. Martín Valtierra Rodríguez
Vocal


Firma

Ing. Eduardo Martínez Segoviano
Suplente


Firma

Centro Universitario
Querétaro, Qro.
Noviembre 2022

RESUMEN

El alcohol como sustancia psicoactiva ha sido utilizada durante siglos en todo el mundo y posee propiedades que pueden ocasionar la dependencia a esta sustancia. De acuerdo con la organización mundial de la salud, su consumo excesivo es un factor causal de más de 60 enfermedades y lesiones tales como trastornos mentales y del comportamiento, condiciones gastrointestinales, cáncer, trastornos reproductivos, daños congénitos, cirrosis hepática, así como otros fenómenos que pueden desembocar del consumo excesivo de alcohol tal como la violencia y los accidentes de tránsito.

Por las razones antes descritas, es de vital importancia estrategias de prevención del alcoholismo. En este sentido, programas psicosociales han presentado ciertos avances con respecto a la detección de la predisposición de una persona a ser alcohólica; sin embargo, estos programas no son suficientes para detectar de manera muy acertada la predisposición de un paciente a sufrir esta enfermedad, debido a que los pacientes/personas presentan diversos factores que los encaminan a tener una dependencia del alcohol tales como factores genéticos, ambientales, depresión y estrés. Por lo tanto, es indispensable la investigación de nuevas alternativas para la detección de personas con predisposición al alcoholismo. En este sentido, en este trabajo de tesis se presenta una metodología basada en la descomposición de modos variacional, indicadores estadísticos y redes neuronales para la clasificación y detección de pacientes con predisposición al alcoholismo empleando señales electroencefalográficas obtenidas de una base datos de acceso libre titulada "Predisposición genética al alcoholismo". Por estas razones, este trabajo de tesis implementa una metodología capaz de clasificar señales EEG de personas control y de personal con predisposición al alcoholismo.

Palabras clave: Señales electroencefalográficas, descomposición de modos variacional, detección de predisposición al alcoholismo, redes neuronales, indicadores estadísticos, análisis de varianza.

DEDICATORIA

Este trabajo de tesis ha sido un largo camino, con sus altos y bajos, pero lo que siempre fue una constante en este proceso, fue el incondicional apoyo y paciencia de mi familia, que sin su respaldo no hubiera sido posible terminar este trabajo; por esto, le dedico este trabajo a mis padres, que a pesar de que no han sido los mejores años últimamente, siempre han creído en mí apoyándome y alentándome en todo momento, nunca voy a dejar de estar agradecido por eso.

Así como también, a mi asesor, el Dr. Juan Pablo, por creer en mí y siempre brindarme su apoyo durante este trabajo, sin su ayuda no hubiera sido posible completar esta tesis.

Finalmente, le dedico este trabajo a todos mis familiares y amigos que directa o indirectamente me han brindado su apoyo, para ser una mejor persona tanto profesional como ser humano.

AGRADECIMIENTOS

En todo mi camino siendo foráneo universitario, he tenido la fortuna de tener a muchas personas que me han brindado su amistad, consejos, amor, sabiduría, etc. Porque sin su apoyo, no habría llegado hasta donde estoy y no sería la persona que soy, por eso quiero agradecer a cada una de ellas.

A mi mamá, por siempre estar al pendiente de mí, por la paciencia que me ha tenido y apoyarme en todo lo que hago, por su mensaje diario cuando estaba fuera de casa para desearme un buen día, así como sus lecciones y regaños que me han forjado a ser la persona que soy.

A mi papá, porque sin él no estaría donde estoy, por siempre apoyarme en todo lo que hago, por demostrarme como ser una persona responsable y honorable, por todo lo que has trabajado, para que nunca me falte nada, gracias.

A mis hermanas Daniela y María José, por confiar en mí y a pesar de las peleas y discusiones, sé que toda la vida puedo contar con ustedes y van a estar conmigo.

A mis abuelitos, Josefina e Inocencio, por todos sus consejos, lecciones de vida, pero sobre todo amor y cariño. A mi abuelita Amelia también, por siempre creer en mí y enseñarme a dar lo mejor de mí.

A mis tíos, Araceli y Jaime, por todo su apoyo que me han dado, por animarme y apoyarme en los momentos adversos que he tenido, por todo su cariño, amor y atención que me han brindado.

A mis primos, Emiliano y Cecilia, por su apoyo incondicional en los momentos difíciles, así como sus consejos. También a mis primas Alejandra y Aneel, por creer en mí y todo lo que hemos vivido todos juntos,

A mis asesores, el Dr. Juan Pablo Amézquita, el Dr. Carlos Pérez, el Dr. Martín Valtierra y al Ing. Eduardo Segoviano, por siempre apoyarme en todo este camino, por creer siempre en mis capacidades, y siempre brindarme su ayuda y consejos. Así como todos mis profesores que me han brindado su sabiduría y enseñanzas en toda mi vida universitaria.

A mis tíos, Constanza y Raymundo, por abrirme las puertas de su hogar y hacerme sentir como en casa, por siempre apoyarme y creer en mí.

A todos mis amigos de la universidad, en especial a mis amigos Alberto, Miguel y Emilio, por brindarme su amistad incondicional, hacerme sentir parte de su familia y siempre apoyarme en toda mi vida universitaria. Así como a mis amigos, María Fernanda, Melina, Mariana y Gastón y a todos mis compañeros, por todos los momentos que hemos vivido juntos en toda la universidad.

A mi camarada Toño, por compartir este camino de la tesis conmigo, por siempre creer en mí y siempre apoyarme en todo momento.

A mis amigos, Daniela y Jorge, por su incondicional apoyo y consejos que me han brindado. A mis amigos de la charrería, Jesús, Juan Manuel y Alan, por todas las experiencias que hemos vivido, así como su incondicional apoyo en todo lo que he necesitado.

Finalmente, agradecer a toda mi familia y amigos, por creer en mí y siempre apoyarme en todo mi camino como universitario.

ÍNDICE GENERAL

RESUMEN	III
DEDICATORIA.....	IV
AGRADECIMIENTOS	V
ÍNDICE GENERAL	VII
ÍNDICE DE FIGURAS	IX
ÍNDICE DE TABLAS	XI
Capítulo 1	1
1.1 Introducción	2
1.2. Antecedentes.....	3
1.3. Descripción del Problema.....	6
1.4. Justificación.	7
1.5. Hipótesis	8
1.6. Objetivos.....	8
1.6.1. Objetivo General	8
1.6.2. Objetivos Particulares	9
1.7. Planteamiento General	9
Capítulo 2	11
2.1 Revisión literaria	12
2.2 Sistema nervioso	12
2.3 Electroencefalografía y las señales EEG.....	14
2.2.1 Características de una señal EEG	16
2.2.2 Sistema empleado para la medición de señales EEG	21
2.4 Procesamiento digital de señales	22
2.4.1 MATLAB	23
2.4.2 Descomposición de modos variacional	24
2.4.3 Indicadores estadísticos	27
2.4.4 Método de Kruskal-Wallis	29
2.4.5 Redes neuronales	30
Capítulo 3	33
3.1 Metodología propuesta	34

3.2	Material (Base de Datos).....	35
3.3	Sistema de adquisición de señales EEG	36
3.4	Análisis en tiempo real de la señal	39
Capítulo 4	51
4.1	Puesta de experimento	52
4.2	Resultados.....	53
4.3	Discusión de resultados.....	65
Capítulo 5	67
5.1	Conclusiones	68
5.2	Prospectivas	70
	Bibliografía.	71

ÍNDICE DE FIGURAS

Figura 1.1. Planteamiento General.....	10
Figura 2.1. Estructura de una neurona típica en la corteza motora del cerebro (Guyton et al., 2017).....	13
Figura 2.2. Ejemplo del potencial de acción (Sanei & Chambers, 2007).....	14
Figura 2.3. Señal EEG (Autoría propia).....	15
Figura 2.4 Potencial de acción y potencial postsináptico (Im, 2018).	16
Figura 2.5. Ilustración de las cinco bandas de frecuencia, de altas a bajas frecuencias, respectivamente (Sanei & Chambers, 2007).	19
Figura 2.6. Sistema internacional de posicionamiento 10-20 (Malmivuo, 1995)....	22
Figura 2.7. Escritorio de Matlab ® (Autoría propia).	24
Figura 2.8. Estructura básica de una red neuronal multicapa (Smith, 1999).....	32
Figura 3.1. Diagrama de la metodología propuesta.	34
Figura 3.2. Posición de cada electrodo de acuerdo al sistema internacional de posicionamiento 10-20 (Grabner & De Smedt, 2012).....	37
Figura 3.3. Gorra utilizada para la adquisición de las señales EEG (Electro-Cap International, s/f).....	38
Figura 3.4 Primera señal EEG sintética (Autoría propia).....	40
Figura 3.5. Segunda señal EEG sintética (Autoría propia).....	41
Figura 3.6. Primera y segunda descomposición de los anchos de banda de la primera señal (Autoría propia).....	41
Figura 3.7. Tercera y cuarta descomposición de los anchos de banda de la primera señal (Autoría propia).....	42
Figura 3.8. Primera y segunda descomposición de los anchos de banda de la segunda señal (Autoría propia).	42
Figura 3.9. Tercera y cuarta descomposición de los anchos de banda de la segunda señal (Autoría propia).	43
Figura 3.10. Gráfica de barras para el primer ancho de banda.	45
Figura 3.11. Gráfica de barras para el segundo ancho de banda.	46
Figura 3.12. Gráfica de barras para el tercer ancho de banda.	48
Figura 3.13. Gráfica de barras para el tercer ancho de banda.	49
Figura 4.1. Representación aproximada de los sujetos durante el experimento (Marchesotti et al., 2016).....	52

Figura 4.2. Ejemplos de las imágenes utilizadas como estímulos (Snodgrass & Vanderwart, 1980).....	53
Figura 4.3. Señal proveniente del electrodo número 10 (F_{c6}) de un paciente sano.	54
Figura 4.4. Señal proveniente del electrodo número 10 (F_{c6}) de un paciente alcohólico.	55
Figura 4.5. IMFs del nivel 1 al 5, del electrodo número 10 (F_{c6}) de un paciente sano.	56
Figura 4.6. IMFs del nivel 6 al 10, del electrodo número 10 (F_{c6}) de un paciente sano.	56
Figura 4.7. IMFs del nivel 1 al 5, del electrodo número 10 (F_{c6}) de un paciente alcohólico.	57
Figura 4.8. IMFs del nivel 6 al 10, del electrodo número 10 (F_{c6}) de un paciente alcohólico.	57
Figura 4.9. Diagrama de caja para la IMF 5, provenientes del electrodo 60 (P_2), para el indicador valor medio cuadrático.....	59
Figura 4.10. Diagrama de caja para la IMF 6, provenientes del electrodo 12 (F_{c2}), para el indicador valor medio cuadrático.....	60
Figura 4.11. Diagrama de caja para la IMF 6, provenientes del electrodo 60 (P_2), para el indicador valor medio cuadrático.....	61
Figura 4.12. Diagrama de caja para la IMF 6, provenientes del electrodo 25 (P_z), para el indicador valor medio cuadrático.....	62
Figura 4.13. Diagrama de caja para la IMF 6, provenientes del electrodo 12 (F_{c2}), para el indicador valor medio cuadrático.....	63

ÍNDICE DE TABLAS

Tabla 2.1. Bandas y rangos de frecuencia de los ritmos cerebrales (Siuly et al., 2016).....	17
Tabla 3.1. Lista de los electrodos colocados por región en el cerebro (Grabner & De Smedt, 2012; Zhang et al., 1995).	37
Tabla 3.2. Valores de los indicadores estadísticos para el primer ancho de banda.	43
Tabla 3.3. Valores de los indicadores estadísticos para el segundo ancho de banda.	45
Tabla 3.4. Valores de los indicadores estadísticos para el tercer ancho de banda.	46
Tabla 3.5. Valores de los indicadores estadísticos para el cuarto ancho de banda.	48
Tabla 4.1. Características más discriminantes conformadas por el electrodo, indicador estadístico y nivel de IMF.	63
Tabla 4.2. Matriz de confusión	65

Capítulo 1

Introducción

1.1 Introducción

El alcohol como sustancia psicoactiva ha sido utilizada durante siglos en todo el mundo y posee propiedades que pueden ocasionar la dependencia a esta sustancia. De acuerdo a la OMS (Organización mundial de la salud, 2018), su consumo excesivo es un factor causal de más de 60 enfermedades y lesiones tales como trastornos mentales y del comportamiento, condiciones gastrointestinales, cáncer, trastornos reproductivos, daños congénitos, cirrosis hepática, así como otros fenómenos que pueden desembocar del consumo excesivo de alcohol tal como la violencia y los accidentes de tránsito.

Desarrollar una dependencia al alcohol, conlleva un conjunto de fenómenos conductuales, cognitivos y fisiológicos en los cuales el consumo de alcohol se convierte en algo primordial para el sujeto, en comparación con otras actividades u obligaciones que en el sujeto solían tener mayor importancia (López Trigo et al., 2013). El alcoholismo se establece como una problemática mundial, produciendo 3 millones de muertes en el mundo debido a su consumo nocivo, representando aproximadamente un 5.3% de todas las defunciones (OMS, 2018). En particular, en México de acuerdo con la Encuesta Nacional de Drogas, Alcohol y Tabaco 2016-2017 (ENCODAT), el porcentaje de dependencia se sitúa en 6.2% y va en aumento. Asimismo, muestra que, de acuerdo con los 11,356 reportes registrados, el 8.6% de los reportes se encontró evidencia de alguna sustancia, siendo el alcohol la de mayor frecuencia^[mvr1] (Villatoro-Velázquez et al., 2017). Por otra parte, entre las causas frecuentes de decesos bajo la influencia del alcohol, el suicidio (77.38%) tiene el porcentaje más alto, seguido del homicidio (68.8%) y los accidentes (62.2%) (Villatoro-Velázquez et al., 2017).

Por las razones antes descritas, es de vital importancia estrategias de prevención del alcoholismo. En este sentido, programas psicosociales han presentado ciertos avances con respecto a la detección de la predisposición de una persona a ser alcohólica (Díaz-Anzaldúa et al., 2011); sin embargo, estos programas no son suficientes para detectar de manera muy acertada la predisposición de un paciente a sufrir esta enfermedad, debido a que los pacientes/personas presentan diversos factores que los encaminan a tener una

dependencia del alcohol tales como factores genéticos, ambientales, depresión y estrés (Díaz-Anzaldúa et al., 2011). En este sentido, se requiere investigar un nuevo método o metodología que permita identificar la predisposición de un paciente a sufrir de alcoholismo con el objetivo de que el paciente en un futuro pueda tomar acciones de prevención para evitar desarrollar esta enfermedad.

1.2. Antecedentes

En la última década, los investigadores se han centrado en el análisis de señales fisiológicas (señales provenientes del cuerpo humano) ya que éstas permiten capturar el estado físico y mental de un paciente, así como su predisposición a ciertas enfermedades (Bermúdez Cicchino, 2013). En este sentido, en los últimos años, se han publicado diversas investigaciones a nivel internacional enfocadas en la detección de un paciente con predisposición a sufrir alcoholismo usando señales electroencefalográficas (EEG). Estas señales se caracterizan por contener los impulsos eléctricos que se emiten en el cerebro humano, las cuales pueden ser asociadas a un fenómeno estudiado, tales como eventos musculares, epilepsia, etc. (Gómez Figueroa, 2016; Smith, 2005). Por ejemplo, Yazdani y Setarehdan (2007) cambiaron indicadores estadísticos tales como la media y la varianza con diferentes clasificadores estadísticos (p. ej., bayes con kernel gaussiano, bayes con estimador de vecinos cercanos (KNN), clasificador k-vecino más cercano y el clasificador de distancia media mínima) para clasificar alcohólicos y personas sanas empleando señales EEG. Los autores reportan que una eficiencia del 90% es obtenida para distinguir entre ambos grupos. En este trabajo se analizan 45 señales de EEG de pacientes con alcoholismo y 30 señales EEG correspondientes con personas sanas, las cuales fueron adquiridas de la base de datos de acceso libre “Predisposición genética al alcoholismo” provista por Henri, (1999). Los trabajos presentados en esta sección emplean la misma base de datos. Padma Shri y Sriraam (2012) emplearon la entropía espectral para extraer características de la banda gamma de las señales EEG para diferenciar entre un grupo normal y un grupo con predisposición al alcoholismo. Los autores mencionan

que los valores entregados por la entropía espectral fueron empleados para entrenar y validar una red neuronal con el fin de obtener un diagnóstico automático, obteniendo una eficiencia del 88%. Por otro lado, Upadhyay et al., (2015) integró diversos indicadores estadísticos (p. ej., media, desviación estándar, asimetría y curtosis), transformada wavelet y redes neuronales para distinguir de forma automática entre ambos grupos (pacientes con predisposición al alcoholismo y normales), alcanzando una eficiencia del 88.57%. Rachman et al., (2017) combinó la transformada wavelet, el análisis de componentes independiente y una red neuronal probabilística para determinar de manera automática entre una persona normal y una con predisposición a ser alcohólica, obteniendo como resultado una eficacia del 85%. Muralidhar Bairy et al. (2017) integraron diferentes indicadores (p. ej., Entropía, Relevancia máxima y redundancia mínima basada en entropía difusa, entre otros) con la transformada wavelet y una máquina de soporte vectorial (SVM) como clasificador con el fin de diferenciar entre ambos grupos de manera automática. Los autores reportan una eficiencia del 94.58%, analizando 60 señales EEG: 30 con predisposición al alcoholismo y 30 sujetos normales. Abdulrahman (2019) investigó diferentes características/medidas no lineales (p. ej., entropía de muestra, entropía gráfica y entropía de Shannon) para identificar patrones dentro de las señales EEG de 12 personas alcohólicas y 12 personas sanas en conjunto con un SVM para distinguir entre ambos grupos de manera automática, alcanzando una eficiencia del 92.5%. Recientemente, Kumari et al., (2020) combinaron diferentes características (p. ej., entropía aproximada, entropía de muestra, movilidad, complejidad, dimensión de correlación, exponente de Lyapunov y entropía espectral) con un SVM para distinguir entre ambos grupos de manera automática. Los autores reportan que su método es capaz de diferenciar entre ambos grupos con una eficiencia del 91.5%; sin embargo, los autores concluyen que es importante seguir evaluando nuevos métodos con el fin de poder incrementar la eficiencia de distinción entre ambos grupos. Los trabajos reportados a nivel internacional han presentado resultados alentadores en la distinción entre personas sanas y personas con predisposición al alcoholismo; sin embargo, es importante seguir evaluando nuevos métodos/metodologías con el fin de incrementar la

eficiencia en la distinción de ambos grupos. Adicionalmente, es importante que estos nuevos métodos sean de una complejidad computacional baja con el fin de poderlos implementar en un sistema/hardware de bajo costo, a diferencia de los trabajos antes reportados donde hacen uso de una gran cantidad de métodos limitando su posible implementación en un sistema hardware.

Con respecto a trabajos reportados a nivel nacional, estos se han enfocado en el uso de cuestionarios para realizar un diagnóstico temprano de alcoholismo (Serrano-Cuevas, 1977); así como en el uso de manual de detección temprana e intervención breve para bebedores problema (Echeverría S.V. et al., 2008), el cual tiene como objetivo ayudar a los pacientes a comprometerse en la modificación de su propia conducta, usando sus recursos y fuerza para cambiar el patrón de su consumo excesivo de alcohol (Cabrera Sosa & Rodríguez Sandoval 2007), aunque en algunos casos es difícil evaluar la efectividad del modelo, debido a que se requiere que el paciente asista a una serie de sesiones para ser evaluado (Trejo Capula, 2014); sin embargo, este tipo de estudio a través de un cuestionario no es del todo eficaz y tienen demasiadas variables tales como factores ambientales, la depresión, el estrés, variantes genéticas, las cuales pueden influir en el resultado final. Por lo tanto, es importante seguir evaluando nuevos métodos tales como la identificación de patrones o características a través de señales fisiológicas que permitan tener una mejor eficacia en la distinción de personas sanas y personas con predisposición al alcohol.

Finalmente, con respecto a nivel local en específico dentro de la Universidad Autónoma de Querétaro (UAQ) se encuentran varios trabajos que se han enfocado a la distinción de ciertas enfermedades. Por ejemplo, Vega (2016) implementó un sistema basado en imágenes provenientes de una cámara termográfica para detectar mujeres con cáncer de mama. Cruz (2018) combinó la dimensión fractal con la descomposición empírica de modos, y redes neuronales para la clasificación de la imaginación motora empleando señales EEG de manera automática. Por otro lado, Vargas (2019) integró los indicadores no lineales, entropías y fractales con redes neuronales para predicción de un infarto hasta 25 minutos antes de este

sucediera. Finalmente, Piña (2019) combinó la dimensión fractal con la lógica difusa para predecir un infarto hasta 1 hora antes de su aparición de manera automática. Recientemente, Vargas (2022) investigó diversos indicadores estadísticos tales como media, varianza, desviación estándar, entre otros, en combinación con un SVM para estimar cuando una persona sufría de estrés o no. Por lo tanto, de acuerdo con lo investigado en a nivel local, aunque se han propuesto diversos trabajos referentes diagnóstico de enfermedades, en lo referido al diagnóstico entre personas sanas y con predisposición al alcoholismo, recientemente Franco Vergara, (2021) combinó la dimensión fractal con herramientas tiempo frecuencia, para identificar la predisposición al alcoholismo en señales EEG, sin embargo faltan investigaciones que se enfoquen en este tema. Por lo tanto, este trabajo de tesis busca implementar una nueva metodología que permita encontrar características capaces de identificar la predisposición a desarrollar alcoholismo a través del análisis de las señales EEG.

1.3. Descripción del Problema

El consumo excesivo de alcohol pone en riesgo tanto al que lo consume como a las personas que lo rodean, ya que una persona alcoholizada tiende a provocar riñas o accidentes que ponen en riesgo su vida (Villatoro-Velázquez et al., 2017; OMS, 2018). A nivel internacional se observó que a través de la adquisición y análisis de señales fisiológicas tales como señales EEG existe la posibilidad de poder detectar pacientes con una predisposición de sufrir alcoholismo (Kumar et al., 2012; Muralidhar Bairy et al., 2017; Abdulrahman, 2019). Sin embargo, es muy importante mencionar que las señales EEG se caracterizan por ser señales con características no estacionarias (sus propiedades tales como amplitud, frecuencia, fase, etc., cambian a través del tiempo), con muy baja amplitud y embebidas en una gran cantidad de ruido así como otros factores tales como potenciales relacionados al movimiento ocular, descargas neuromusculares debido al movimiento muscular; señales provenientes de los electrodos; señales de ruido de la red, etc. (Shanbao & Nitish V.Thankor, 2018). De tal modo, que la principal problemática que ha surgido

en estos últimos es la identificación de patrones o características dentro de estas señales que sean capaces de detectar la predisposición de un paciente a sufrir alcoholismo con una buena eficiencia. Por esta razón, es este trabajo de investigación se evaluará una nueva metodología basada en la descomposición de modos variacional, indicadores estadísticos y redes neuronales con la finalidad de encontrar características en señales EEG que sean capaces de poder distinguir entre personas sanas y personas con predisposición a sufrir alcoholismo de manera automática, tratando de lograr una mayor eficiencia que los trabajos antes mencionados en la sección de antecedentes a través de algoritmos de muy baja complejidad computacional.

1.4. Justificación.

Una persona que consume en exceso alcohol está expuesta a sufrir diferentes tipos de patologías tales como trastornos mentales y comportamentales, enfermedades no transmisibles como la cirrosis hepática, ciertos tipos de cáncer y enfermedades cardiovasculares, las cuales ponen en riesgo la vida de una persona que consume una gran cantidad de alcohol (García Rodríguez et al., 2014). Por lo que, si una persona que sufre de alcoholismo llega a tener una de las patologías antes mencionadas, por lo general las personas cercanas/familiares son las que le ayudan a la persona/paciente a realizar sus tareas básicas y en ciertos casos absorber los costos de los tratamientos para estas enfermedades, los cuales pueden ser bastante elevados si la enfermedad es detectada en un estado avanzado (Torre-Delgadillo et al., 2013).

Por estas razones, surge la necesidad de identificar de manera oportuna una persona con una predisposición al consumo excesivo de alcohol. Por lo tanto, la justificación principal de este trabajo de tesis es el desarrollar una metodología a través de técnicas de procesamiento avanzado que permita la identificación de características que permitan la distinción entre personas sanas y personas con predisposición a sufrir alcoholismo a través de señales fisiológicas, lo que le

permitiría al paciente/persona en tomar las medidas necesarias para reducir el riesgo de sufrir numerosas enfermedades que son acarreadas con el alcoholismo, así como una posible muerte.

La base de datos a emplear (Henri, 1999), ha mostrado buenos resultados en investigaciones en los últimos veinte años, pese a que la base de datos no sea tan reciente, los problemas relacionados con el alcoholismo se han mantenido a lo largo de los años, incluso se prevé que el consumo de alcohol aumente en los próximos 10 años (OMS, 2018), acarreado consigo las problemáticas que rodean al alcoholismo.

1.5. Hipótesis

Mediante la combinación de la descomposición de modos variacional, indicadores estadísticos (p. ej., desviación estándar, varianza, kurtosis, etc.) y redes neuronales se generará una metodología de baja complejidad computacional, basada en el número de indicadores empleados en comparación con otros estudios, que permita distinguir entre personas sanas y personas con predisposición a sufrir de alcoholismo a través de señales EEG, y con ello mejorar la eficiencia de distinción entre ambos grupos comparado con los trabajos reportados actualmente.

1.6. Objetivos

1.6.1. Objetivo General

Proponer y desarrollar una nueva metodología de baja complejidad computacional conservando una eficiencia adecuada que permita su implementación en hardware de bajo costo, basada en la descomposición de modos variacional, indicadores estadísticos (p. ej., los algoritmos de varianza, kurtosis, desviación estándar, etc.) y redes neuronales para identificar personas que son susceptibles a sufrir alcoholismo a través de señales EEG.

1.6.2. Objetivos Particulares

1. Desarrollar un algoritmo de lectura de señales EEG mediante el uso del software MATLAB para el ordenamiento adecuado de estas señales provenientes de la base de datos de acceso libre “Predisposición genética al alcoholismo” provista por Henri, (1999) y mencionada en los antecedentes (<https://archive.ics.uci.edu/ml/datasets/EEG+Database>).
2. Programar la descomposición de modos variacional haciendo uso del software MATLAB para descomponer las señales EEG en sus diferentes bandas de frecuencia de acuerdo con su información frecuencial contenida en la señal.
3. Programar los diversos algoritmos de los indicadores estadísticos tales como varianza, desviación estándar, kurtosis, momentos, etc. haciendo uso del software MATLAB para estimar las características de una señal en el dominio del tiempo.
4. Realizar un análisis estadístico o análisis de varianza para poder estimar los indicadores estadísticos más discriminantes para detectar personas con susceptibilidad al alcoholismo.
5. Diseñar un clasificador basado en una red neuronal, usando los indicadores estadísticos más discriminantes obtenidos en el objetivo 4 para poder detectar automáticamente a personas con susceptibilidad al alcoholismo.
6. Evaluar todas las pruebas contenidas en la base de datos de manera estadística con el fin de validar la eficiencia de la metodología propuesta buscando realizar la detección personas con predisposición al alcoholismo de manera eficiente.

1.7. Planteamiento General

En la Figura 1 se muestra el planteamiento general de la tesis, el cual consiste en tres etapas que son descritas a continuación:



Figura 1.1. Planteamiento General.

1. **Señales EEG.** En la primera etapa del planteamiento general se enfoca al ordenamiento de las señales EEG, las cuales describen la actividad eléctrica del cerebro de personas sanas y personas con predisposición al alcoholismo. Las señales EEG analizadas se encuentran en la base de datos de acceso libre llamada “Predisposición genética al alcoholismo”, la cual constan de 45 señales EEG de personas sanas y 77 señales EEG de personas con predisposición genética al alcoholismo.
2. **Procesamiento de la señal.** Una vez entendidas y leídas las señales EEG de la base de datos, estas serán procesadas a través de diversas técnicas de procesamiento avanzadas con el objetivo de encontrar características dentro de estas señales que permitan asociarlas al fenómeno que se está estudiando (la distinción entre personas con predisposición a sufrir de alcoholismo y de personas que no)
3. **Clasificador.** Finalmente, las características más adecuadas identificadas en la etapa anterior, estas son empleadas para entrenar y validar un clasificador que permita distinguir entre personas que tienen predisposición a sufrir alcoholismo y personas que no de manera automática.

Capítulo 2

Fundamentación teórica

2.1 Revisión literaria

Como se mostró en el capítulo anterior, este trabajo de tesis se basa en el desarrollo de una metodología basada en la descomposición de modos variacional, indicadores estadísticos y redes neuronales, para la clasificación de señales EEG con el propósito de detectar pacientes con predisposición a desarrollar alcoholismo. En este capítulo se presentan los temas y los conceptos necesarios referentes a señales EEG y la colocación de electrodos para adquirirlas, así como la matemática que describe la descomposición de modos variacional, los indicadores estadísticos, análisis de varianza y redes neuronales.

2.2 Sistema nervioso

El sistema nervioso se caracteriza por ser la principal herramienta de información en el cuerpo humano, debido a la gran cantidad de procesos que se lleva a cabo, principalmente organizando las actividades del cuerpo humano, tales como los numerosos estímulos provenientes de múltiples nervios en el cuerpo para después retroalimentar o dar una respuesta a dichos estímulos dependiendo de la zona de los cuales estos provengan. (Guyton et al., 2017). Por lo tanto, el sistema nervioso se divide en dos partes fundamentales, el sistema nervioso central; conformado por el encéfalo y la medula espinal; y el sistema nervioso periférico formado el sistema nervioso autónomo y el sistema nervioso somático (Guyton et al., 2017).

En particular, el cerebro o encéfalo se divide en tres partes; cerebro, cerebelo y el tronco cefálico. El cerebro se divide en dos hemisferios, derecho e izquierdo, cada uno se divide en cuatro lóbulos: frontal, parietal temporal y occipital (Siuly et al., 2016). Siendo el cerebro, la parte que es asociada con las funciones cerebrales, tales como movimientos, emociones, pensamientos y funciones motoras, está cubierto por la corteza cerebral, una fina capa de tejido neuronal. La cual, debido a su localización en la superficie del cerebro, tiene una mayor influencia en los registros de las señales EEG.

La neurona es la unidad funcional básica del sistema nervioso, existen aproximadamente más de 100,000 millones de ellas. Las cuales están conformadas

principalmente por: dendritas, encargadas de recibir y procesar la información recibida; el cuerpo celular que contiene el núcleo de la neurona; el axón, el cual surge del cuerpo celular para después dividirse en muchas ramificaciones, las cuales se conectan con otras terminales nerviosas del sistema nervioso o del cuerpo humano, estas conexiones se les da el nombre de sinapsis, en la cual se da el intercambio de información de neurona a neurona, como se muestra en la Figura 2.1 (Guyton et al., 2017).

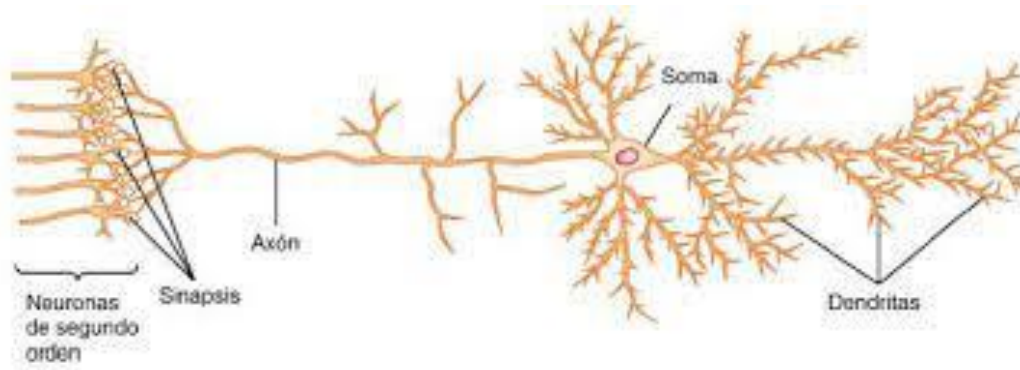


Figura 2.1. Estructura de una neurona típica en la corteza motora del cerebro (Guyton et al., 2017).

Por otra parte, al recibir estímulos de diferentes tipos, por ejemplo, al escuchar con los oídos, de manera visual con el sentido de la vista, mediante el tacto con nuestro cuerpo, entre otros, es cuando el sistema nervioso lleva a cabo la mayor parte de sus funciones y actividades. Estos estímulos o experiencias sensitivas, provocan una reacción en nuestro organismo, ya sea generando una respuesta al instante en el cerebro o guardarla para una respuesta corporal en el futuro (Guyton et al., 2017). En particular, cuando son recibidos dichos estímulos, se desencadena una serie de reacciones en el organismo, activando la comunicación entre neuronas, la información transmitida, lo que se conoce como potencial de acción (Sanei & Chambers, 2013). Estos potenciales de acción son causados debido a que hay un intercambio de iones en los canales de sodio y potasio de la membrana celular, provocando un cambio de potencial en la membrana de la célula, el cual es transmitido a través del axón de la neurona,

produciendo una despolarización del potencial de la membrana, es decir, se vuelve más positiva, generando una curva, después se genera una repolarización de la membrana, volviéndose más negativa, incluso más que el potencial de reposo, volviendo después a la normalidad, todo este proceso tiene una duración de entre 5 y 10 milisegundos, asimismo, el rango de amplitud para un ser humano es de aproximadamente -60 mV y 10 mV; por lo tanto, todo el proceso del potencial de acción contribuye a la generación de las señales EEG, es decir, revelando la actividad cerebral, el cual es descrito en la Figura 2.2 (Sanei & Chambers, 2007).

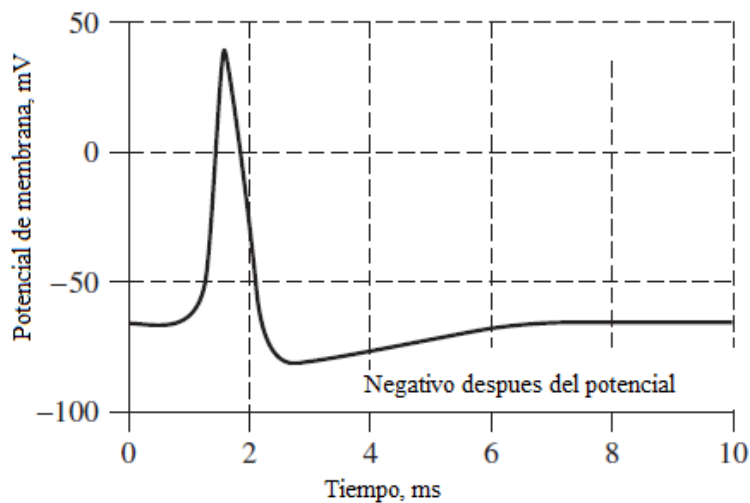


Figura 2.2. Ejemplo del potencial de acción (Sanei & Chambers, 2007).

2.3 Electroencefalografía y las señales EEG.

La electroencefalografía es una técnica que se encarga de monitorear la función del cerebro en tiempo real, demostrando la actividad eléctrica del cerebro a lo largo del tiempo. Este estudio es ampliamente utilizado en la medicina para diagnosticar trastornos neurológicos, tales como epilepsia, tumores cerebrales, heridas en la cabeza etc. Además, esta permite el estudio de las funciones del cerebro (Siuly et al., 2016).

Las señales electroencefalográficas (EEG), como se muestra en la Figura 2.3, son señales que son generadas a partir de la activación de las células neuronales, produciendo flujos de corrientes locales (corrientes sinápticas), estas corrientes generan un campo magnético que es medible por un electrocardiograma y un campo un campo eléctrico secundario, el cual es medido por los sistemas de EEG (Sanei & Chambers, 2013).

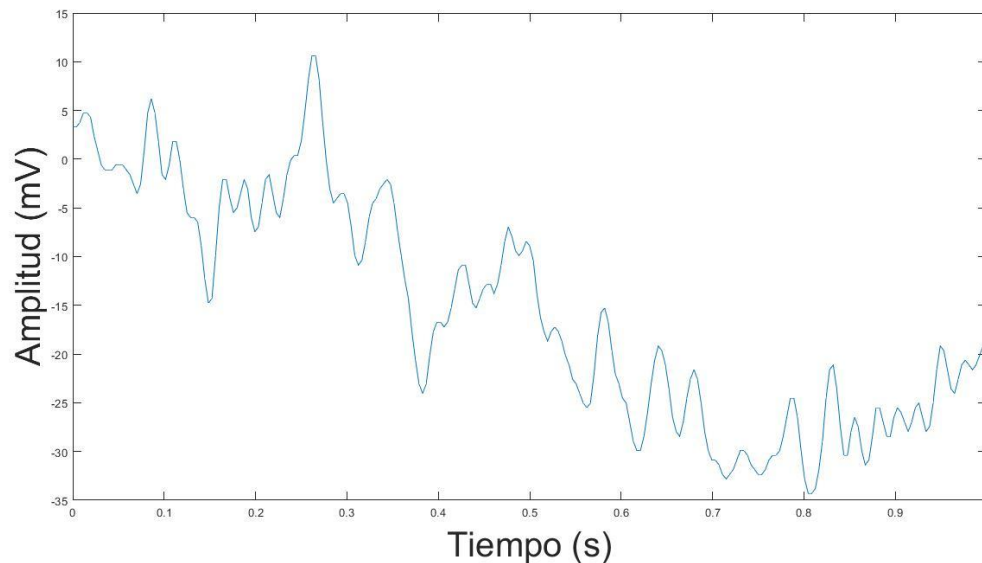


Figura 2.3. Señal EEG (Autoría propia).

Como se describe en párrafos anteriores, el potencial de acción sucede cuando hay una polarización y despolarización en la membrana de la célula neuronal, y contribuye a la generación de las señales EEG (Sanei & Chambers, 2013). Sin embargo, las actividad cerebral se puede atribuir a dos potenciales, el potencial de acción (PA) y el potencial postsináptico (PPS) (Siuly et al., 2016). En la comunicación entre neuronas, la información transmitida dentro de la neurona viaja mediante el potencial de acción, cuando la información llega a la sinapsis, en otras palabras, la unión entre una neurona presináptica y una neurona postsináptica, se genera el potencial postsináptico, el cual se transmite a través de la membrana de la neurona postsináptica. Si el potencial postsináptico supera el umbral (PPS

excitatorio), la información viaja de nuevo mediante el potencial de acción hacia otra neurona, de lo contrario, si no alcanza el umbral (PPS inhibitorio), no se genera el potencial de acción. (Im, 2018).

Los potenciales eléctricos que son reconocidos en el cuero cabelludo para la obtención de las señales EEG, se cree que son generados mayormente por los potenciales postsinápticos (Im, 2018). A pesar de que el potencial de acción es mayor en amplitud, los potenciales postsinápticos se ocasionan simultáneamente y en una gran cantidad de neuronas además de tener una mayor duración (Siuly et al., 2016), como se muestra en la Figura 2.4. En particular, en la parte izquierda de esta figura, se observa que el potencial de acción es de mayor amplitud; sin embargo, es de menor duración, en cambio, el potencial postsináptico es de menor amplitud pero con mayor duración, finalmente, en la derecha de la figura, la gran cantidad de neuronas activas simultáneamente pueden generar la actividad eléctrica suficiente para ser registrada en la superficie del cuero cabelludo (Im, 2018).

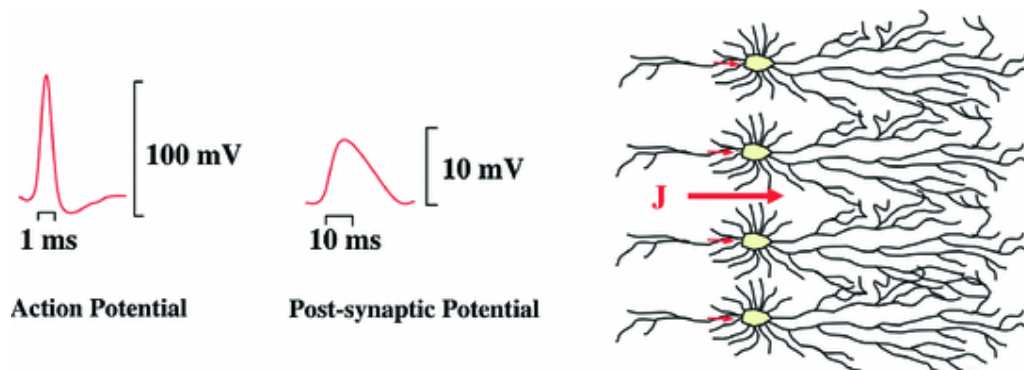


Figura 2.4 Potencial de acción y potencial postsináptico (Im, 2018).

2.2.1 Características de una señal EEG

A lo largo de los años, las señales EEG han sido empleadas en diversas aplicaciones tales como (Birbaumer, 2006; Sanei & Chambers, 2007; Schröder et al., 2005):

- Monitorear el estado de coma, muerte cerebral.
- Distinguir ataques epilépticos.

- Monitorear el desarrollo del cerebro.
- Investigar trastornos fisiológicos, de sueño y mentales.
- Probar los efectos de los medicamentos para la epilepsia.
- Investigar drogas para efectos convulsivos.
- Investigar la epilepsia y localizar el origen de las convulsiones.
- Localizar áreas de daño después de una lesión en la cabeza, un accidente cerebrovascular o algún tumor.
- Entre otras

A pesar de que las señales EEG han sido empleadas en numerosas aplicaciones, es de suma importancia mencionar que surge la necesidad de la aplicación de técnicas avanzadas de procesamiento para poderlas analizar de manera correcta y en base a ello poder interpretar los diferentes trastornos en el cuerpo humano. Para ello, es importante identificar y relacionar la información contenida en las señales, identificando sus características morfológicas o examinando las bandas de frecuencia asociadas con las actividades mentales o estados conscientes del cuerpo humano.

La frecuencia es una de las herramientas más utilizadas para investigar trastornos dentro de las señales EEG, y se refiere a la actividad repetitiva rítmica (Siuly et al., 2016). Para dividir la información, se agrupan las frecuencias en bandas o también llamados ritmos, las cuales se distinguen en cinco bandas principales por sus diferentes rangos de frecuencia; estas bandas de frecuencia se distinguen de bajas a altas: delta (δ), theta (θ), alpha (α), beta (β) y gamma (γ), las cuales son enumeradas en la Tabla 2.1 en conjunto con su rango se muestran las bandas de frecuencias, así como también los rangos de las mismas en Hertzios (Hz) (Siuly et al., 2016), posteriormente se describen la información de cada banda de frecuencia.

Tabla 2.1. Bandas y rangos de frecuencia de los ritmos cerebrales (Siuly et al., 2016).

Banda de frecuencia	Rango de Frecuencia (Hz)
---------------------	--------------------------

Delta (δ),	0.5 – 4 Hz
Theta (θ),	4 – 8 Hz
Alpha (α),	8 – 13 Hz
Beta (β)	13 – 30 Hz
Gamma (γ)	>30 Hz

El primer ritmo, delta, se caracteriza por tener la mayor amplitud, pero también la menor frecuencia; su rango de frecuencia esta entre 0.5 a 4 Hz. Está principalmente relacionado con los estados de sueño profundo, trastornos cerebrales graves y con el estado de vigila (Siuly et al., 2016). Por otra parte, el ritmo theta, cuyo rango esta entre 4 a 8 Hz, y amplitud ronda alrededor los 20 μ V. Este ritmo se presenta mayormente en el estrés emocional, principalmente derivado de la frustración o decepción, y por la parte del inconsciente, la inspiración creativa y meditación profunda(Siuly et al., 2016).

El ritmo Alpha, rango de frecuencia entre 8 a 13 Hz, amplitud de 30 a 50 μ V, se ubican principalmente en la región posterior de la cabeza, es decir por la región del lóbulo occipital. Este ritmo está relacionado con los estados de relajación y desconexión, es decir, donde el cerebro presenta un poco actividad neuronal (Sanei & Chambers, 2007). La banda beta, rango frecuencial entre 13 a 30 Hz (detectada principalmente en la región frontal y central del cerebro), normalmente posee una baja amplitud, por debajo de los 30 μ V. Esta banda se vincula principalmente cuando el cerebro esta despierto, es decir, está relacionado con el pensamiento activo, la atención activa, la resolución de problemas (Siuly et al., 2016).

Finalmente, el ritmo gamma, con frecuencias superiores a 30 Hz y una amplitud demasiado baja. Esta banda está asociada a funciones cognitivas y motoras (Siuly et al., 2016). Es muy importante mencionar que, a pesar de que existen diversas bandas, es de gran relevancia analizar las señales EEG de acuerdo a la información frecuencial que pudiera contener con el fin de poderla asociar al fenómeno estudiado.

En la Figura 2.5 presenta una ilustración los diferentes ritmos de ondas cerebrales, con sus respectivos niveles de amplitud.




Figura 2.5. Ilustración de las cinco bandas de frecuencia, de altas a bajas frecuencias, respectivamente (Sanei & Chambers, 2007).

Por otra parte, al momento de adquirir las señales EEG una de las grandes preocupaciones es la adquisición de diferentes tipos de señales de interferencia también conocidas como señales espurias, artefactos o ruido, que es cualquier componente registrado dentro de las señales EEG, sin embargo, no es directamente generado por la actividad eléctrica del cerebro per se (Urigüen & Garcia-Zapirain, 2015). Estas señales espurias, artefactos o ruido, provocan alteraciones en las señales pudiendo simular anomalías o convulsiones en las señales EEG lo que puede derivar en una errónea interpretación de las señales EEG, o un mal diagnóstico (Sazgar & Young, 2019). Los artefactos se pueden clasificar en dos, los artefactos que se originan dentro del cuerpo humano, artefactos fisiológicos y los artefactos no fisiológicos, originados por el entorno del paciente (Urigüen & Garcia-Zapirain, 2015).

Los artefactos fisiológicos son alteraciones en las señales EEG a causa de otros procesos fisiológicos en el cuerpo humano (Sweeney et al., 2012). Las

principales fuentes del ruido detectado relacionado con los artefactos fisiológicos son (Urigüen & Garcia-Zapirain, 2015):

- **Ruido generado por el movimiento de los ojos.** El movimiento ocular ocasiona una distorsión en el campo eléctrico, de la misma manera que el parpadeo de los ojos incluso generando un cambio más abrupto que el movimiento ocular, además este ruido puede ser, en amplitud, muchas veces mayor que las señales EEG de interés (Sweeney et al., 2012).
- **Ruido producido por la actividad muscular.** Este ruido es comúnmente ocasionado en pacientes despiertos, derivado de tragar, caminar, hablar, hacer tensión en los músculos del cuello, hacer muecas, etc. Este tipo de ruido depende del grado de contracción muscular y el tipo de musculo que está haciendo movimiento, por tal motivo resulta difícil clasificar, de acuerdo a la forma y amplitud (Urigüen & Garcia-Zapirain, 2015).
- **Ruido proveniente de la actividad cardiaca.** Aunque suele ser de poca amplitud en el cuero cabelludo, es generado por la actividad eléctrica del corazón, de la misma manera, el latido de corazón también produce ruidos de pulso, a causa de la contracción y expansión de los vasos sanguíneos, este tipo de ruido es generalmente causado cuando un electrodo se coloca sobre un vaso sanguíneo pulsante, sin embargo, se soluciona colocando correctamente los electrodos (Urigüen & Garcia-Zapirain, 2015).
- **Ruido de fuentes poco comunes.** Además de los ruidos previamente descritos, existen otros tipos de ruido poco comunes, como el ruido generado por la piel, el movimiento de la lengua, ruido generado por los movimientos de respiración (Urigüen & Garcia-Zapirain, 2015).

Por otra parte, el ruido no fisiológico es aquel ruido generado a causa del ambiente alrededor del cuerpo del paciente, que puede ser causado por distintas fuentes, por ejemplo: electrodos, movimientos de cabe, interferencias eléctricas y movimientos corporales, entre otros (Sweeney et al., 2012). Las interferencias por el ambiente se pueden suprimir por medio de un filtro, a causa de la estrecha banda

frecuencia de los aparatos eléctricos (60-50 Hz) y que la frecuencia de la interferencia no está en el mismo rango de las bandas de frecuencia de las señales (Urigüen & Garcia-Zapirain, 2015).

2.2.2 Sistema empleado para la medición de señales EEG

Para el registro de la actividad cerebral, sensores denotados como electrodos se colocan sobre el cuero cabelludo en diferentes localizaciones, los cuales como se mencionó en apartados anteriores, son capaces de detectar la actividad eléctrica del cerebro, para después esta ser enviada a un sistema de adquisición (Siuly et al., 2016). Para la colocación de los electrodos en el cuero cabelludo, la Federación Internacional de Sociedades de Encefalografía recomienda el sistema internacional de posicionamiento 10-20, el cual describe en que posición del cráneo se deben de colocar los electrodos para medir las señales EEG (Sanei & Chambers, 2013). En dicho sistema, el "10" y "20" se refiere a la distancia entre electrodos vecinos, por lo que puede ser de 10% o 20% de la distancia total de adelante hacia atrás, o de derecha a izquierda del cráneo (Siuly et al., 2016).

Como se muestra en la Figura 2.6, las posiciones se encuentran determinadas por cuatro referencias, el nasión (punto entre la frente y nariz), el inión (en la prominencia ósea en la parte posterior del cráneo, en la línea media), además de que cada localización de electrodo tiene una letra para identificar el lóbulo del cerebro donde se encuentra y un número, para identificar en que hemisferio se localiza. Las letras F, C, T, P y O se refieren a los lóbulos frontal, central, temporal, parietal y occipital respectivamente, a pesar de que no exista un lóbulo central, se utiliza para una mejor localización (Sanei & Chambers, 2013). Los números pares indican los electrodos en el hemisferio derecho, en cuanto a los números impares, se refieren a los electrodos en el hemisferio izquierdo. Por otro lado, la letra "z" se refiere a un electrodo localizado en la línea media del cráneo, y frecuentemente los electrodos A1 y A2, son utilizados como electrodos de referencia, localizados en los lóbulos de la oreja izquierda y derecha respectivamente (Siuly et al., 2016).

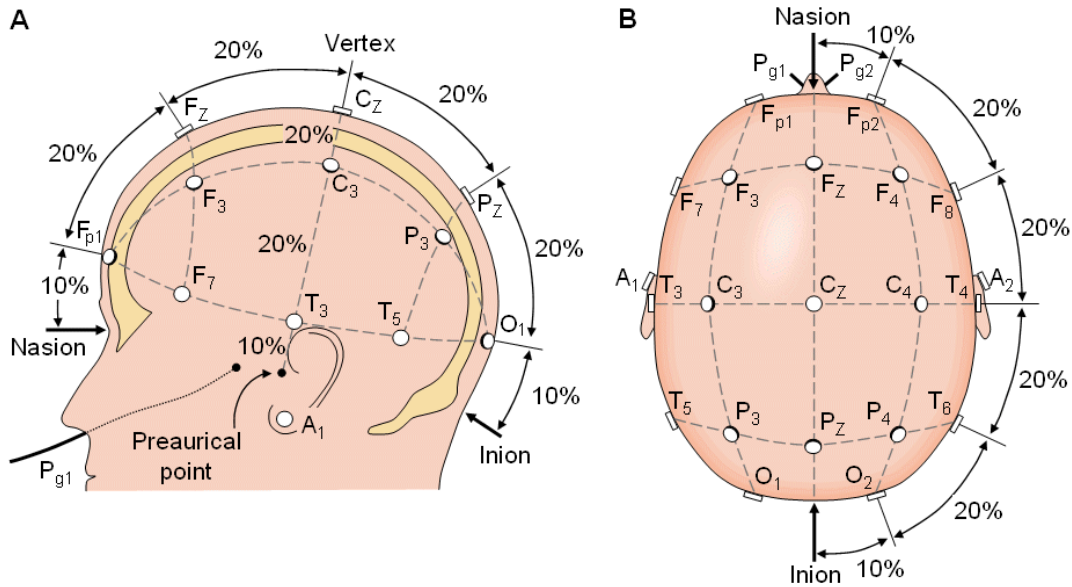


Figura 2.6. Sistema internacional de posicionamiento 10-20 (Malmivuo, 1995).

2.4 Procesamiento digital de señales

El procesamiento digital de señales ha tenido grandes avances a lo largo de los años en diferentes áreas de la sociedad, tales como espacial, militar, industrial, telefonía, comunicación, médica, etc. (Smith, 1999). Esta rama de la ingeniería se distingue de otras debido a que se maneja un tipo particular de información, las señales, las cuales surgen de todos los campos de la ciencia e ingeniería, además de que pueden surgir de ciertos procesos fisiológicos o surgir artificialmente (Antoniou, 2006), una señal se define como cualquier cantidad física que varía con el tiempo, espacio o cualquier variable o variables independientes (Rao & Swamy, 2018).

En otras palabras, el procesamiento es la manipulación de la señal transmitida o recibida, con diferentes propósitos, tales como: mejorar la calidad de la señal; extraer o alterar información de la misma; reconocimiento de patrones; compresión de información etc. (Barchiesi, 2008). Las señales son manipuladas a través de una serie de operaciones matemáticas, algorítmicas y lógicas, dicho conjunto de operaciones se describen como transformaciones matemáticas (Tan &

Jiang, 2013), de esta manera, la información puede ser analizada, manipulada o transformada según sea el interés de la investigación.

Cabe resaltar que, sin el procesamiento digital de señales, los científicos, investigadores, ingenieros, no tendrían las suficientes herramientas para analizar, interpretar, diseñar y comprender toda la información de interés que está dentro de las señales, con el objetivo de desarrollar nuevos avances en la ciencia. Si no existieran los sistemas de diagnóstico para señales EEG, de rayos X o imágenes médicas, los aparatos médicos serían menos eficientes, a causa de que no proporcionarían información de utilidad para un diagnóstico preciso (Tan & Jiang, 2013).

2.4.1 MATLAB

MATLAB (Matrix Laboratory) es un programa de alto rendimiento orientado al cálculo con vectores o matrices (señales digitales), con el cual se utilizan muchos algoritmos que resuelven problemas ingenieriles, siendo los usos más comunes (A Undarraga & Venegas, 2005):

- Desarrollo de algoritmos.
- Adquisición de datos.
- Modelación y simulación de prototipos.
- Desarrollo de aplicaciones.

El escritorio de Matlab se puede muestra en la Figura 2.7, el cual se divide en diferentes ventanas: el command window o ventana de comandos, la cual es usada para ingresar variables, ejecutar funciones y manipular datos; workspace o ventana de espacio de trabajo, la cual es utilizada para indicar las variables que han sido creadas a lo largo de la programación, así como su valor de las mismas; current folder o directorio actual, esta ventana muestra los archivos con los cuales se está trabajando y por último el editor, el cual es utilizado para crear y editar los programas que se desean ejecutar en Matlab.

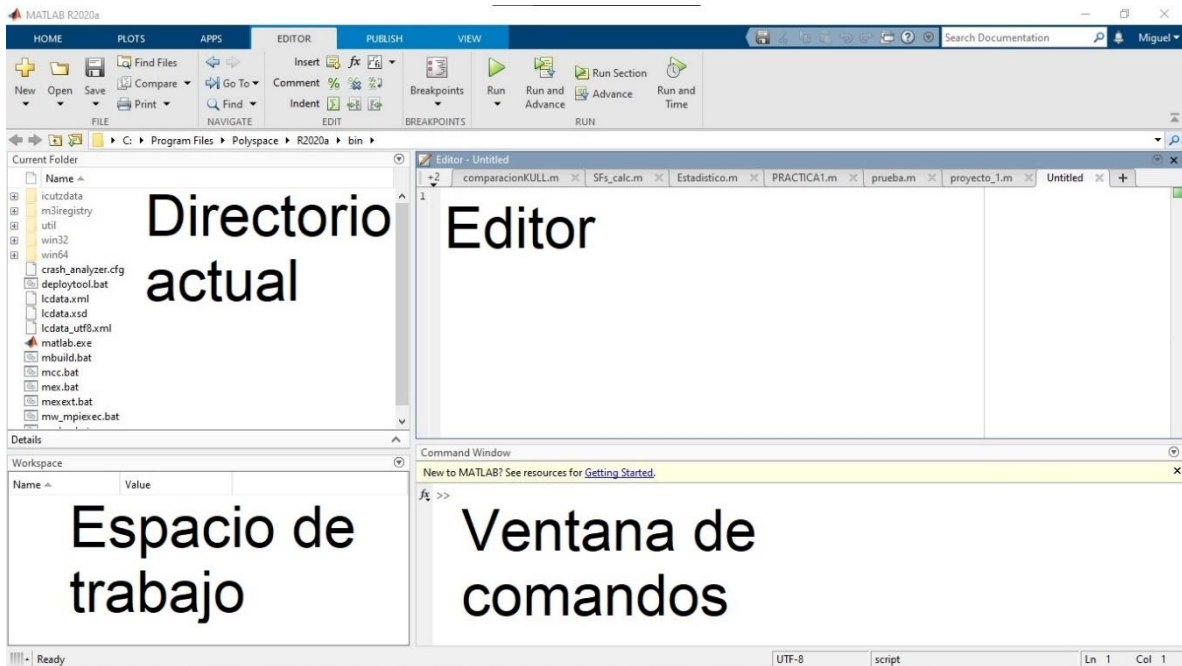


Figura 2.7. Escritorio de Matlab ® (Autoría propia).

2.4.2 Descomposición de modos variacional

El método de descomposición de modos variacional (VMD) es un método algorítmico adaptativo y recursivo, para detectar y descomponer una señal en sus principales "modos" (Dragomiretskiy & Zosso, 2014). A diferencia del método de descomposición empírica de modos (EMD) donde también se descomponen las señales en modos (Huang et al., 1998), EMD utiliza un enfoque no recursivo, es decir, no permite la corrección de errores hacia atrás y no puede manejar el ruido correctamente (Pandey & Seeja, 2022). Por otra parte, el VMD tiene una base matemática más robusta, ayudando a mejorar la precisión con la que es separada la señal (Brzostowski & Świątek, 2021). De igual forma, el VMD determina las bandas de frecuencia de manera adaptativa, además simultáneamente, estima los modos correspondientes, de esta manera equilibra los errores que pudieran surgir entre ellos (Dragomiretskiy & Zosso, 2014).

En primer lugar, es de suma importancia la definición de un modo o también llamado función de modo intrínseco (IMF), los cuales son señales de amplitud y frecuencia modulada definidas como (Dragomiretskiy & Zosso, 2014):

$$\mu_k = A_k(t) \cos(\phi_k(t)) \quad (2.1)$$

donde $k = 1, 2, \dots, K$, K representa el número predefinido de modos, la fase $\phi_k(t)$ es una función no decreciente $\phi_k'(t) \geq 0$, la envolvente no es negativa $A_k(t) \geq 0$, y lo más importante, tanto la envolvente $A_k(t)$ como la frecuencia instantánea $W_k(t) := \phi_k'(t)$ varían mucho más lento que la fase $\phi_k(t)$ (Dragomiretskiy & Zosso, 2014).

Cuando la descomposición de la señal está completa, la señal original $y(t)$ puede ser expresada como (Brzostowski & Świątek, 2021):

$$y(t) = \sum_{k=1}^K u_k(t) \quad (2.2)$$

Por lo tanto, VMD se enfoca en descomponer una señal de valor real de entrada, en un número discreto k de subseñales (IMF), donde cada componente o modo tiene propiedades de dispersión específicas en su ancho de banda, mientras reproduce la señal de entrada (Dragomiretskiy & Zosso, 2014). Cada subseñal o modo tiene un ancho de banda bien limitado en el dominio espectral alrededor de una frecuencia central (frecuencia de interés) (Hu et al., 2019), de este manera, se considera que cada subseñal está, en su mayoría, cercanamente a la frecuencia central correspondiente, en otras palabras, el ancho de banda se mantiene al mínimo entre la frecuencia central y el modo (Liu et al., 2016).

Para evaluar el ancho de banda de un modo, es empelado un problema de optimización variacional como se describe a continuación (Dragomiretskiy & Zosso, 2014):

1. La señal real es transformada a una señal analítica mediante el uso de la transformada de Hilbert, $(\delta(t) + \frac{1}{\pi t}) * u_k(t)$, para formar un espectro frecuencial unilateral de la frecuencia, es decir, el espectro de frecuencias para las frecuencias negativas es nulo o se eliminan.

2. El espectro de frecuencia es modulado a la banda base, mezclándose o multiplicándose con una función exponencial, $e^{-iw_k(t)}$, la cual es sintonizada con la frecuencia central $[(\delta(t) + \frac{1}{\pi t}) * u_k(t)]e^{-iw_k(t)}$.
3. El ancho de banda es estimado a través de la norma cuadrada del gradiente de la señal modulada. En VMD la identificación de los modos es un problema de optimización, donde el objetivo es minimizar la suma de los anchos de banda, de tal manera que la suma de todos los modos sea equivalente a la señal original, donde el problema de optimización variacional y la función objetivo son definidos como:

$$\begin{cases} \min_{\{u_k\}, \{w_k\}} \{ \sum_k \|\partial_t [(\delta(t) + \frac{1}{\pi t}) * u_k(t)] e^{-iw_k(t)}\|_2^2 \} \\ \text{s. t. } \sum_k u_k = f. \end{cases} \quad (2.3)$$

donde $\{u_k\} := \{u_1, \dots, u_K\}$ y $\{w_k\} := \{w_1, \dots, w_K\}$ se refieren al conjunto de todos los modos y sus frecuencias centrales respectivamente, del mismo modo que $\sum_k u_k = f$ se refiere a la suma de todos los modos, y f es la señal original que se descompuso en k cantidad de modos (Dragomiretskiy & Zosso, 2014).

La Ecuación (2.3) con restricciones es resulta mediante la introducción del operador de multiplicación de Lagrange, convirtiendo el problema con restricción en un problema sin restricciones, resultando de la siguiente manera:

$$\begin{aligned} \mathcal{L}(\{u_k\}, \{w_k\}, \lambda) := & \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 + \|f(t) - \\ & \sum_k u_k(t)\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle, \end{aligned} \quad (2.4)$$

Por la tanto, la ecuación resultante, Ecuación (2.4), es resuelta con el método de multiplicadores de Lagrange con direcciones alternadas (ADMM) (Dragomiretskiy & Zosso, 2014), donde todos los modos que son obtenidos de las soluciones en el dominio espectral son definidos como:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2}, \quad (2.5)$$

donde w_k es la frecuencia correspondiente, $\hat{u}_k^{n+1}, \hat{f}(w), \hat{\lambda}(w)$ son las transformadas de Fourier que corresponden a $u_k^{n+1}, f(\omega), \lambda(\omega)$, respectivamente, y n se refiere a la n -ésima iteración. Por otra parte, las frecuencias centrales de los componentes son determinadas mediante (Dragomiretskiy & Zosso, 2014):

$$\omega_k^{n+1} = \frac{\int_0^\infty w |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega}, \quad (2.6)$$

De acuerdo a la Ecuación (2.6), la nueva frecuencia central ω_k es colocada en el centro de gravedad del espectro del modo correspondiente.

A pesar de que las investigaciones en señales fisiológicas basadas en VMD son pocas, este método ha sido utilizado en la clasificación de ataques epilépticos (Ravi Kumar & Srinivasa Rao, 2018), detección de apnea de sueño (Mahmud et al., 2021), eliminación de ruido (Kaur et al., 2019; Lahmiri, 2016), entre otros, mostrando resultados prometedores. Para ver más a detalle el algoritmo completo del VMD se puede encontrar en Dragomiretskiy & Zosso, 2014.

2.4.3 Indicadores estadísticos

El procesamiento de señales consiste básicamente en aplicar una transformación u operación matemática a una señal de entrada w , con el objeto de extraer información, mejorar la señal, u obtener un patrón/característica oculto, etc. (Gray & Davisson, 2004). La estadística dentro del procesamiento de señales es utilizada para formular modelos matemáticos apropiados para describir el comportamiento de una señal, desarrollar técnicas para la identificación de parámetros o características dentro de la señal, entre otros (Kannan & Kundu, 2001). De la misma forma, los indicadores estadísticos han sido utilizados en diferentes estudios con señales no estacionarias como las del cuerpo humano, siendo capaces de detectar cambios en señales relacionadas con enfermedades neurodegenerativas (Xia et al., 2015), enfermedades cardíacas (Ghorbani Afkhami et al., 2016), trastornos de sueño (Hassan & Hassan Bhuiyan, 2016), así como también predicción de ataques epilépticos (Perez-Sanchez et al., 2020), entre otros.

Por estas razones, esta tesis se centra en su investigación con el fin de poder asociarlas a la distinción de personas con predisposición al alcoholismo

Las ecuaciones (2.7) a (2.12) describen los indicadores estadísticos empleados en este trabajo de tesis, así como con sus fórmulas para cada indicador (Abdullah, 2005; Devore & Berk, 2012; Estrella, 2008; U. Palaniswamy, 2005; Quevedo, 2011).

a) Moda

La moda es el dato que aparece con mayor frecuencia en una distribución de datos, es decir, es el valor más repetido en un conjunto, el cual se describe matemáticamente por:

$$X_{mo} = mode(x_i) \quad (2.7)$$

b) Valor cuadrático medio (RMS)

El valor cuadrático medio o el segundo momento estadístico, es utilizado para cuantificar el contenido total de energía de una señal y está definido por:

$$X_{rms} = \left(\frac{1}{N} \sum_{i=1}^N x_i \right)^{\frac{1}{2}} \quad (2.8)$$

c) Valor medio cuadrático (SMR)

Al igual que el RMS, el SMR permite estimar la energía de una señal pero tomando en cuenta que todos sus datos son positivos y se define de la siguiente manera:

$$X_{smr} = \left(\frac{1}{N} \sum_{i=1}^N |x_i|^{\frac{1}{2}} \right)^2 \quad (2.9)$$

d) Rango

La definición de rango hace referencia a la diferencia entre los extremos de los datos de un conjunto, es decir, mide la dispersión de los datos. Este indicador es representado mediante:

$$X_{rg} = \max(x_i) - \min(x_i) \quad (2.10)$$

e) Varianza

La varianza se conoce como una medida de dispersión, la cual mide la variabilidad de los datos con respecto a su valor medio y está definida por:

$$X_{\sigma^2} = \frac{1}{N-1} \sum_{x=i}^N x_i^2 \quad (2.11)$$

f) Desviación estándar.

La desviación estándar se caracteriza por medir la dispersión de los datos con base en su media. Este indicador es calculado mediante la formula:

$$X_{\sigma} = \sqrt{X_{\sigma^2}} \quad (2.12)$$

2.4.4 Método de Kruskal-Wallis

El método Kruskal-Wallis (KWD) es un método de análisis de varianza no paramétrico (no requiere que la población tenga una distribución normal) que tiene como objetivo diferenciar o comparar si dos o varios datos provienen o no de la misma población (Kruskal & Wallis, 1952; Theodorsson-Norheim, 1986; Yanez-Borjas et al., 2020). Este método ha sido utilizado en diferentes áreas del procesamiento de señales fisiológicas, tales como detección de esquizofrenia en señales EEG (Siuly et al., 2020) y detección de señales focales de EEG, que son señales que aparecen en ataques de epilepsia, pero solamente en ciertas áreas del cerebro (Acharya et al., 2019; Gupta et al., 2017), entre otros.

KWM calcula el valor de probabilidad (valor p), el cual indica la probabilidad de rechazar la hipótesis (hipótesis nula) que establece que no existe diferencia entre dos o más conjuntos de datos (Chan & Walmsley, 1997; Hecke, 2012). Para realizar esta tarea, KWM evalúa las medianas de los conjuntos de datos y en base estas establece el valor p , el cual si es menor que un rango de aceptación o hipótesis nula, comúnmente seleccionada en un rango de 0.05 a 0.01 (Hecke, 2012; Kruskal & Wallis, 1952), entonces la hipótesis nula se rechaza, lo cual indica que alguna de las medias es mayormente diferente a las demás. De la misma forma, si el valor de la probabilidad es mayor que el rango establecido (Hecke, 2012), la hipótesis nula es aceptada, indicando que las medias de los conjuntos de datos es en su mayoría

igual. Ahora, entre más bajo sea el valor p , indica que mayormente se puede diferenciar entre dos o más conjuntos de datos. Por lo tanto, en este trabajo de tesis, el valor de p , se utiliza para obtener que indicadores estadísticos son más discriminativos, con el objetivo de reconocer a los pacientes que predisposición a desarrollar alcoholismo.

2.4.5 Redes neuronales

El aprendizaje automatizado (ML, por sus siglas en inglés), es una rama de la inteligencia artificial encargada de desarrollar algoritmos dinámicos, los cuales con la capacidad de tomar decisiones en base en un conjunto de datos (El Bouchefry & de Souza, 2020), dicho de otro modo, el aprendizaje automático se encarga de elaborar/developar algoritmos y técnicas que permitan a los ordenadores hacer predicciones basadas en datos. Algunos algoritmos de aprendizaje automatizado son supervisados, lo que se refiere a que primeramente se trabaja o entrena con una base de datos y después se hacen predicciones con nuevos datos tomando como base los datos previamente estudiados (El Bouchefry & de Souza, 2020). Por otro lado, los no supervisados hacen predicciones sin un conjunto de datos al inicio.

Dentro de los algoritmos del ML, se encuentran las redes neuronales, este tipo de algoritmos intentan modelar la capacidad del sistema nervioso para reconocer patrones u objetos (El Bouchefry & de Souza, 2020). Dentro de las muchas tareas que realiza el ser humano, se encuentran actividades relacionadas con inteligencia y reconocimiento de patrones u objetos, tales actividades son llevadas a cabo con mucha facilidad, es decir, no requieren demasiado esfuerzo, sin embargo, para las computadoras o máquinas son procesos difíciles de automatizar y realizar (Dongare et al., 2008). Por tal motivo, el desarrollo de algoritmos o técnicas que realicen procesos similares, suponen una gran ayuda para entender cómo se llevan a cabo estos procesos dentro del ser humano.

Las redes neuronales artificiales o ANN (Artificial Neural Network por sus siglas en inglés) se refieren a sistemas computacionales que modelan o simulan la actividad eléctrica del cerebro y el sistema nervioso, y “aprenden” a reconocer

patrones o categorizar datos de entrada, al ser entrenado previamente con una muestra de datos de todo el conjunto (Walczak & Cerpa, 2003), a este proceso se le conoce como “entrenamiento” o “acondicionamiento”, aquí es donde se modifican los factores de ponderación o “pesos” en respuesta a la información de entrada, simulando el fortalecimiento de las conexiones neuronales del cerebro (Matich, 2001).

En las ANN, el análogo de la neurona es el perceptrón (también conocido como elemento procesador), su estructura básica tiene varias entradas, combinándolas y modificándolas mediante una función de transferencia o activación, cuyo valor de salida pasa a la salida del perceptrón (Basogain Olabe, 2001). La salida del perceptrón puede estar conectada a la entrada de otros perceptrones, entonces cada perceptrón recibe entradas de muchos otros perceptrones y transmite su salida a otros perceptrones, simulando la excitación eléctrica de una célula nerviosa y la transmisión de información. Por lo tanto, una red neuronal es un conjunto de elementos procesadores interconectados entre sí, las cuales se pueden organizar en tres capas, la capa de entrada, la capa oculta y la capa de salida (Acevedo et al., 2017).

La Figura 2.8 muestra la estructura básica de una red neuronal multicapa, con las capas de entrada, capa oculta y la capa de salida. De acuerdo con esta figura, cada capa está conformada por uno o más nodos; los nodos de la capa de entrada se denotan como pasivos, es decir, solamente transmiten los valores de su única entrada a sus múltiples salidas, en cambio los nodos de las capas oculta y salida son nodos activos, modifican las señales de entrada, primeramente con sus respectivos pesos o factores de ponderación y finalmente a través de una señal de activación, donde si el valor de salida está por debajo de un umbral determinado, ninguna salida pasa a la neurona siguiente, de lo contrario, si sobrepasa el umbral, la salida pasa a la neurona siguiente (Matich, 2001; Smith W., 1999).




Figura 2.8. Estructura básica de una red neuronal multicapa (Smith, 1999).

Capítulo 3

Metodología

En el presente capítulo se describe la metodología empleada para el procesamiento de las señales EEG en la detección de la predisposición de pacientes a desarrollar alcoholismo, también se explica la base de datos empleada, así como también las etapas de la metodología

3.1 Metodología propuesta

En el presente trabajo se lleva a cabo la metodología propuesta en la Figura 3.1, la cual consiste en 4 etapas:

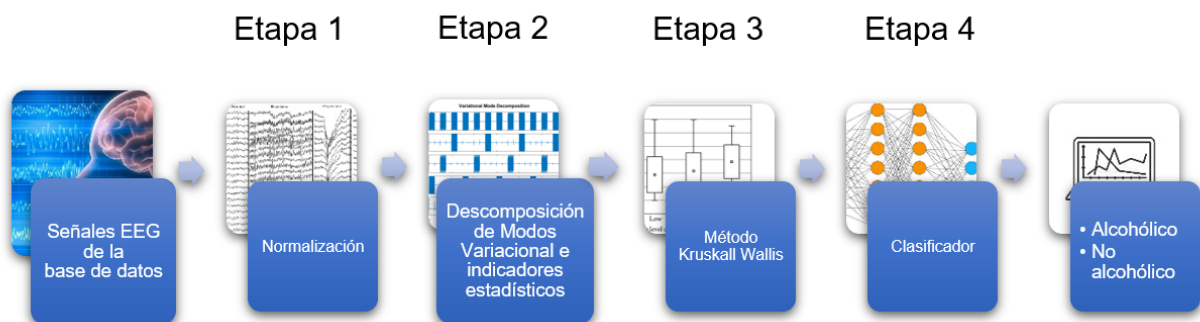


Figura 3.1. Diagrama de la metodología propuesta.

- **Etapa 1. Normalización de las señales EEG:** Primeramente, las señales adquiridas de la base de datos provistas por Henri, (1999), son ordenadas para poder leerlas correctamente en el software MATLAB y facilitar la manipulación de las mismas.
- **Etapa 2. Descomposición de Modos Variacional e indicadores estadísticos:** Posteriormente, después de ordenar y acomodar correctamente las señales EEG, las señales son preprocesadas a través de la Descomposición de Modos Variacional, para poder descomponer las señales en 10 modos o bandas de frecuencia, permitiendo obtener la información frecuencial contenida en la señal. Una vez aplicada la descomposición de modos variacional, a cada uno de los modos o bandas

de frecuencia se les aplican los indicadores estadísticos, tales como: moda, mediana, valor cuadrático medio, valor medio cuadrático, rango, media, varianza y desviación estándar, con el fin de obtener los mejores indicadores capaces de diferenciar las señales.

- **Etapa 3. Método Kruskal Wallis:** Una vez que se obtienen las características de las bandas de frecuencia de las señales EEG, se procede a realizar un análisis estadístico de varianza, a través del método Kruskal Wallis. Este análisis estadístico de varianza, permite determinar cuál o cuáles son las bandas de frecuencia en conjunto con los indicadores estadísticos más discriminantes, para poder detectar a pacientes con predisposición a desarrollar alcoholismo.
- **Etapa 4. Red neuronal:** Finalmente, los indicadores estadísticos más discriminantes seleccionados a través del método Kruskal Wallis, son utilizados para desarrollar una red neuronal que permita diferenciar las señales de los pacientes con susceptibilidad a desarrollar alcoholismo y los que no de manera automática.

3.2 Material (Base de Datos)

En el presente trabajo de tesis se emplea la base de datos de acceso libre llamada “Predisposición genética al alcoholismo” provista por Henri (1999) con el fin de validar la metodología propuesta. En particular, la base de datos empelada en este trabajo de tesis, es una base de datos de acceso libre de la Universidad de California, provista por Henri (1999). La base de datos fue desarrollada con el fin de examinar la predisposición genética de una persona a desarrollar alcoholismo a través de las señales EEG, la cual consta de dos grupos de sujetos: un grupo de sujetos alcohólicos y el grupo control. Los participantes del grupo con alcoholismo constan de 77 participantes hombres con un promedio de edad de 35.83 ± 5.33 y el grupo de control conformado por 48 sujetos varones con un promedio de edad de 36.05 ± 13.75 . Ambos grupos no presentan antecedentes en particular o familiares de abuso de alcohol o algún trastorno neurológico o enfermedad psiquiátrica (Henri, 1999).

Para la adquisición de las señales EEG, los participantes fueron sentados en una silla reclinable, dentro de una habitación aislada con atenuación de sonido, fijándose en una pantalla de computadora ubicada a 1 metro de distancia de los ojos de los participantes. A cada participante se le colocaron 64 electrodos en el cuero cabelludo, tomando como referencia el electrodo "nd", estos fueron colocados de acuerdo con el sistema internacional de posicionamiento 10-20, previamente descrito. Cada señal EEG adquirida se le fijó una frecuencia de muestreo de 256 Hz, donde cada señal tiene un periodo de 190 ms previa al estímulo y 1440 ms después de cada estímulo. Cabe destacar que los ensayos con exceso de movimientos oculares y corporales fueron retirados (Zhang et al., 1995).

En el estudio, cada grupo de sujetos fue expuesto a estímulos, los cuales consisten en una serie de figuras de objetos elegidas de un banco de imágenes de Snodgrass y Vanderwart (1980). Cada participante fue expuesto a un primer estímulo (S1) y a un segundo estímulo (S2), en el cual había dos situaciones, S1 y S2 eran coincidentes o S1 y S2 no eran coincidentes. En la primera situación, S1 fue repetido en el estímulo S2, es decir, eran las mismas figuras, en cambio en la segunda situación, S1 fue seguido de una figura completamente distinta.

3.3 Sistema de adquisición de señales EEG

El sistema de adquisición de datos (SAD) empleado en la base de datos de acceso libre provista por Henri (1999), es descrito a continuación. Primeramente, para adquirir las señales EEG, se emplea un casco con 64 electrodos, los cuales fueron colocados en diferentes áreas en el cuero cabelludo de cerebro de los pacientes. Para el correcto posicionamiento de los electrodos en el cuero cabelludo, fue utilizado el sistema internacional de posicionamiento 10-20, que fue descrito en secciones anteriores, y que se ilustra en la Figura 3.2. De igual manera, la Tabla 3.1 muestra la lista de los electrodos, así como el lugar donde estos fueron colocados.

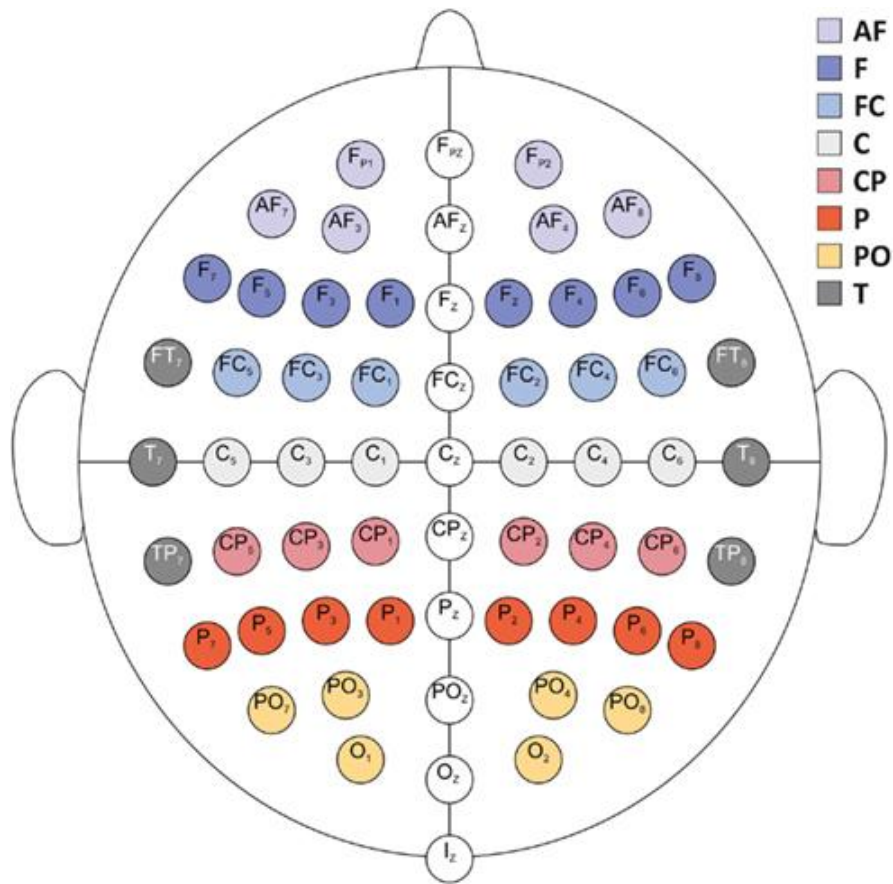


Figura 3.2. Posición de cada electrodo de acuerdo al sistema internacional de posicionamiento 10-20 (Grabner & De Smedt, 2012).

Tabla 3.1. Lista de los electrodos colocados por región en el cerebro (Grabner & De Smedt, 2012; Zhang et al., 1995).

Región	Electrodos	Región	Electrodos
Frontal	FP1, FP2, F7, F8, AF1, AF2, FZ, F4, F3, FC5, FC2, FC1, AFZ, F1, F2, F5, F6., AF7, AF8	Parietal	CP1, CP2, P3, P4, PZ, P8, P7, CP3, CP4, P5, P6, P2, P1, CPZ.
Central	FC6, C3, C4, C1, C2, FC4, FC3, C6, C5, FCZ, CZ.	Occipital	PO2, PO1, O2, O1, PO7, PO8, POZ, OZ.
		Temporal	T8, T7, CP5, CP6, FT7, FT8, FPZ, TP8, TP7.

Conexión a tierra y referencia	El electrodo “nd” es el electrodo de referencia, mientras que los electrodos “X” y “Y”, son los electrodos de las señales EOG.
---------------------------------------	--

Para la adquisición de las señales EEG, fue utilizada la gorra “ElectroCap International”, con 61 derivaciones de electrodos (ver Figura 3.3). Por otra parte, como se mencionó anteriormente, el electrodo “nd” fue utilizado como electrodo de referencia, y la conexión a tierra fue mediante un electrodo de punta con una impedancia de menos de 5 k Ω , además de que los electrodos “X” y “Y”, son utilizados para el registro horizontal y vertical respectivamente, de las señales de electro-ocular bipolar (Anuragi & Sisodia, 2020).



Figura 3.3. Gorra utilizada para la adquisición de las señales EEG (Electro-Cap International, s/f).

Las señales EEG fueron adquiridas con una frecuencia de muestreo de 256 Hz, con un periodo de 190 ms previo a la estimulación y 1440 ms después de cada estímulo. Las señales fueron amplificadas con una ganancia de 10,000 mediante amplificadores Ep-A2 (Sensorium, Inc) y un filtro pasa banda de 0.02 a 50 Hz, lo que permite centrarse en las señales de interés del cerebro con el fin de analizarla en una computadora/ordenador (Zhang et al., 1995).

Como se mencionó anteriormente, cada participante fue expuesto a diferentes estímulos bajo las siguientes condiciones:

- **Condición 1:** Un simple estímulo (S1), fue presentado a los participantes.
- **Condición 2 (situación coincidente):** El estímulo 2 (S2) se repitió como estímulo 1 (S1).
- **Condición 3 (situación no coincidente):** El estímulo 2 (S2), fue seguido por una imagen diferente al estímulo 1 (S1).

3.4 Análisis en tiempo real de la señal

Con el objetivo de ilustrar de una manera más clara las etapas relevantes de la metodología propuesta, descomposición de modos variacional y los indicadores estadísticos, se simulan/analizan dos señales EEG, con información frecuencial diferente una de la otra, que, en este caso en particular, provengan únicamente de un solo sensor. Las señales simuladas están conformadas por cuatro frecuencias, las cuales están dentro de los rangos de las señales EEG antes descritas. Los valores de las frecuencias son: 3, 6, 11 y 45 Hz, para la primera señal, y de 1, 7, 9 y 20 Hz para la segunda señal; con una frecuencia de muestreo de 256 Hz y una duración de 1s, teniendo en total 256 datos por cada señal. Adicionalmente, se agrega ruido aleatorio a las señales simuladas con el fin de obtener una señal más realista. En la Figura 3.4 se muestra un ejemplo de la primera señal simulada, y en la Figura 3.5 se muestra el ejemplo de la segunda señal simulada.




Figura 3.4 Primera señal EEG sintética (Autoría propia).

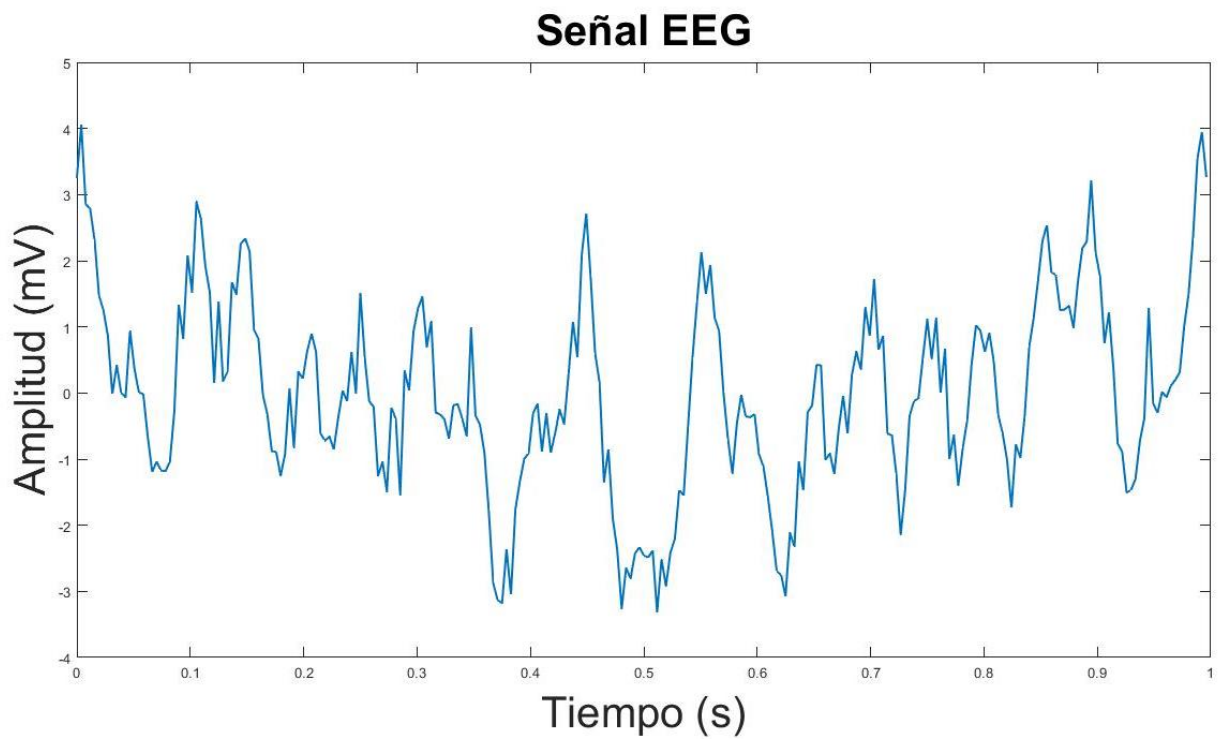



Figura 3.5. Segunda señal EEG sintética (Autoría propia).

Una vez generadas las señales, se procede a descomponerlas a través de la descomposición de modos variacional, con el objetivo de dividir la señal en sus diferentes modos o anchos de banda. Cabe destacar que, cada señal se va a descomponer en cuatro anchos de banda o modos, debido a que es el número de anchos de banda de interés, de manera que la descomposición se realice correctamente.

Las Figuras 3.6 y 3.7 muestran los cuatro anchos de banda o bandas de frecuencia de la primera señal resultantes de aplicar la descomposición de modos variacional. Por otro lado, las Figuras 3.8 y 3.9 presentan los cuatro anchos de banda de la segunda señal.



[mvr2]

Figura 3.6. Primera y segunda descomposición de los anchos de banda de la primera señal (Autoría propia).

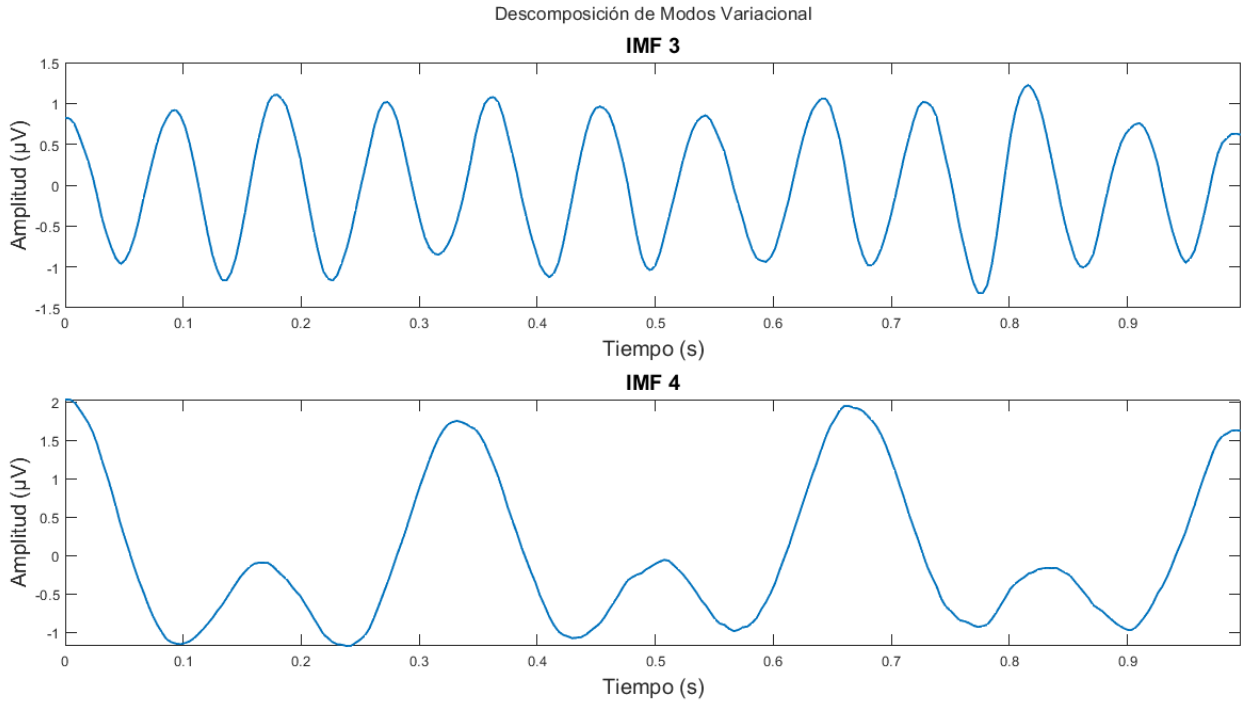


Figura 3.7. Tercera y cuarta descomposición de los anchos de banda de la primera señal (Autoría propia).




Figura 3.8. Primera y segunda descomposición de los anchos de banda de la segunda señal (Autoría propia).




Figura 3.9. Tercera y cuarta descomposición de los anchos de banda de la segunda señal (Autoría propia).

Ya que cada señal es descompuesta en los cuatro anchos de banda a través de la descomposición de modos variacional, se procede a aplicar a cada ancho de banda varios indicadores estadísticos, tales como: moda, mediana, valor cuadrático medio (RMS), valor medio cuadrático (SMR), rango, media, varianza, desviación estándar, skewness, Kurtosis, quinto momento, sexto momento, factor de forma con RMS, factor de forma con SMR, factor cresta, factor impulso y factor latitud.

Las Tablas 3.2, 3.3, 3.4 y 3.5 junto con las Figuras 3.10, 3.11, 3.12 y 3.13 muestran los valores de los indicadores estadísticos con su respectiva gráfica de barras para los anchos de banda primero, segundo, tercero y cuarto, respectivamente de cada una de las señales.

Tabla 3.2. Valores de los indicadores estadísticos para el primer ancho de banda.

Primer ancho de banda		
Indicador estadístico	Primera señal	Segunda señal
Moda	-1.52951365938529	-0.724570227454647

Mediana	0.0267122171308896	-0.00248430296051660
Valor cuadrático medio (RMS)	0.705563889193044	0.294287572289561
Valor medio cuadrático (SMR)	0.577715604471860	0.199779013455505
Rango	2.83674581494030	1.41695344833787
Media	0.000334036119079752	-1.95867064808756e-06
Varianza	0.499772526585058	0.0869448033382877
Desviación estándar	0.706945914893819	0.294864042124990
Skewness	0.00131090157859437	0.184403726027270
Kurtosis	1.63459227875350	2.56010564091944
Quinto momento	-0.0271742335087293	1.10543045739387
Sexto momento	3.27153068682596	9.08706427691072
Factor de forma con RMS	1.11756870045122	1.23917347800516
Factor de forma con SMR	0.915065080865212	0.841220894956833
Factor de cresta	2.16778903060728	2.46211629603480
Factor de impulso	2.42265316978819	3.05098921381063
Factor latitud	2.64752007310510	3.62685857198922

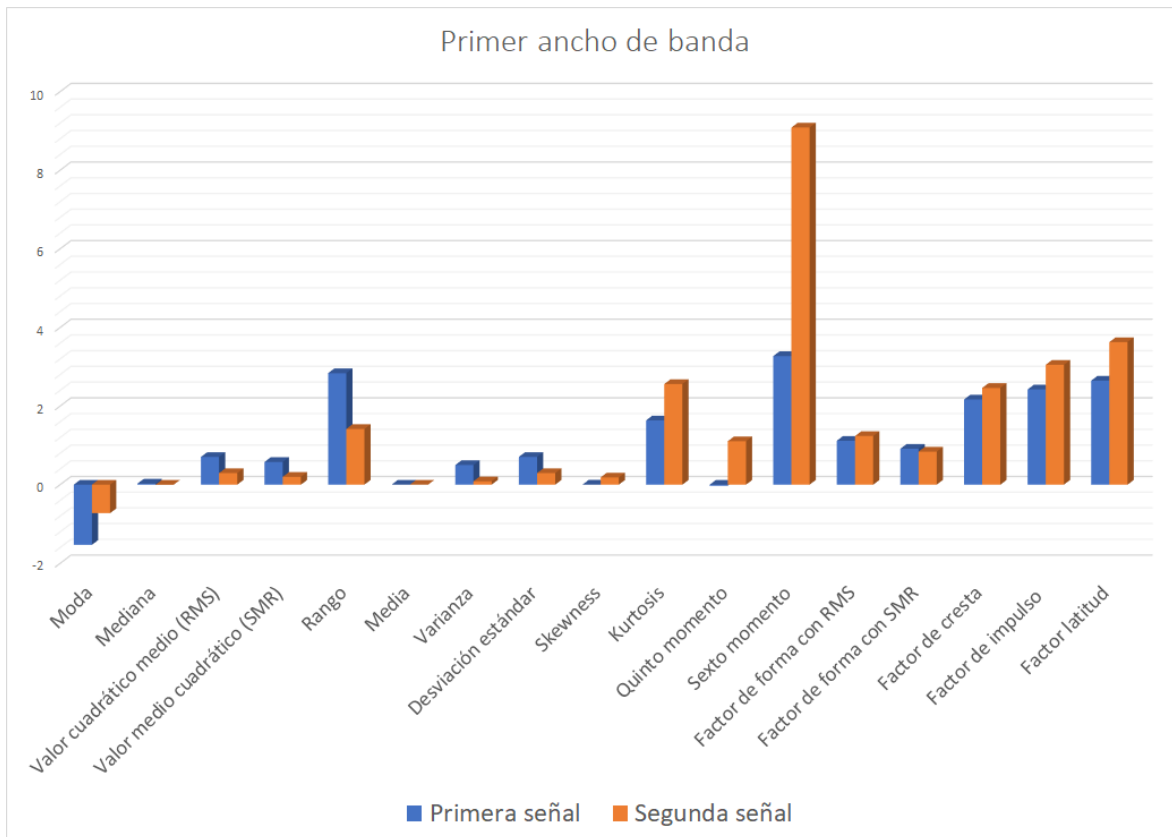


Figura 3.10. Gráfica de barras para el primer ancho de banda.

Tabla 3.3. Valores de los indicadores estadísticos para el segundo ancho de banda.

Segundo ancho de banda		
Indicador estadístico	Primera señal	Segunda señal
Moda	-0.644780755134688	-1.24267298545273
Mediana	-0.00485171039436855	0.0116384942430885
Valor cuadrático medio (RMS)	0.181852729939199	0.688609238807505
Valor medio cuadrático (SMR)	0.121243570762047	0.559281247969680
Rango	1.21062461872154	2.43070200007548
Media	0.000425001832867424	-3.58871439820390e-05
Varianza	0.0331999219549177	0.476042222414471

Desviación estándar	0.182208457418742	0.689958130914095
Skewness	-0.0124581989432506	0.00860666788196160
Kurtosis	3.48247207362478	1.62934012211401
Quinto momento	-0.658732458615271	-0.0150730918019928
Sexto momento	21.3924676669561	3.13223165629809
Factor de forma con RMS	1.27064497964731	1.12209478189236
Factor de forma con SMR	0.847155467805276	0.911353688840726
Factor de cresta	3.54562043335982	1.80461271127399
Factor de impulso	4.50522480338356	2.02494650665717
Factor latitud	5.31806141209858	2.22191069334780

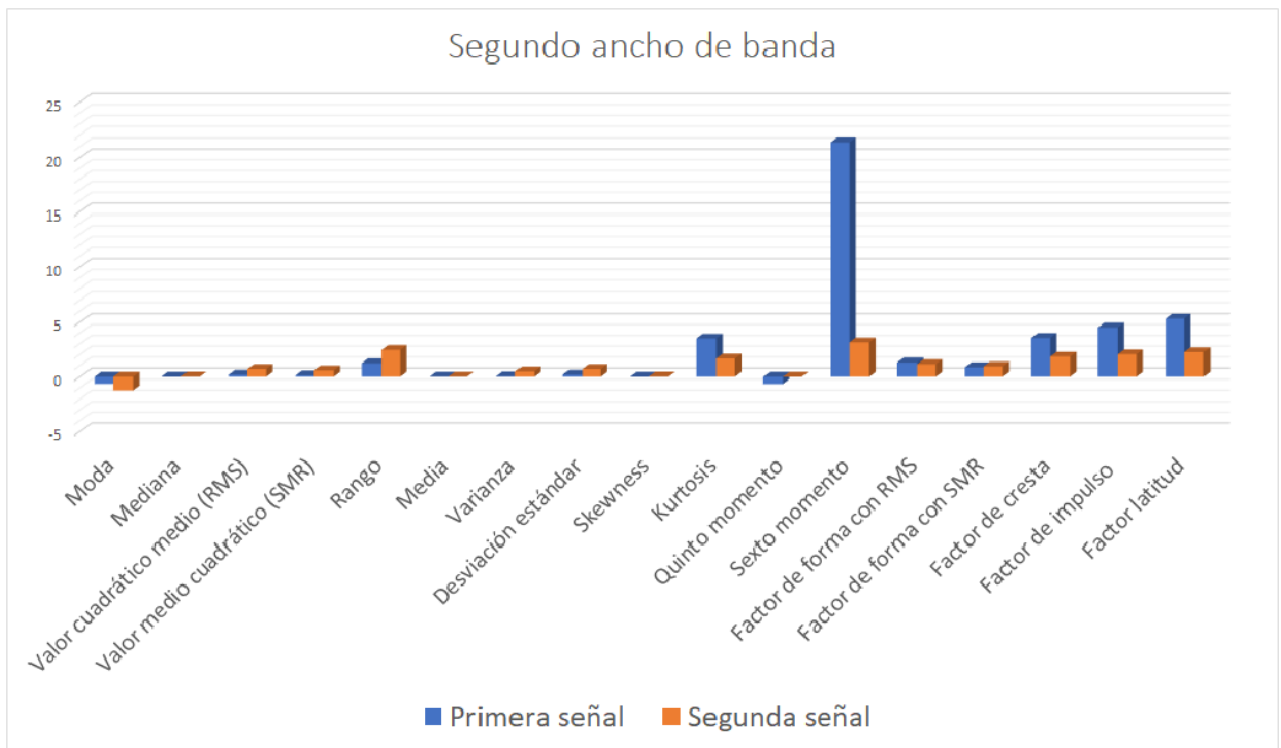


Figura 3.11. Gráfica de barras para el segundo ancho de banda.

Tabla 3.4. Valores de los indicadores estadísticos para el tercer ancho de banda.

Tercer ancho de banda		
Indicador estadístico	Primera señal	Segunda señal
Moda	-1.16085459689490	-2.12223109216284
Mediana	0.00213789014308340	-0.0276939679489425
Valor cuadrático medio (RMS)	0.717397156723293	0.972218725740378
Valor medio cuadrático (SMR)	0.584275758073351	0.650891203700810
Rango	2.38015040927281	4.08415789942972
Media	0.00564033996180546	-0.000225577860932120
Varianza	0.516645011616407	0.948915902539166
Desviación estándar	0.718780224836777	0.974123145469384
Skewness	-0.0109192921715764	0.0197300271891456
Kurtosis	1.58399352729214	2.36940823405440
Quinto momento	-0.0213843316780441	0.0320060563786515
Sexto momento	2.89080032395717	7.10576761050720
Factor de forma con RMS	1.11879337809911	1.24261033499194
Factor de forma con SMR	0.911188235122090	0.831915818179741
Factor de cresta	1.69961060055915	2.18287411667235
Factor de impulso	1.90151308525263	2.71246193736346
Factor latitud	2.08684990867759	3.26050049546890




Figura 3.12. Gráfica de barras para el tercer ancho de banda.

Tabla 3.5. Valores de los indicadores estadísticos para el cuarto ancho de banda.

Cuarto ancho de banda		
Indicador estadístico	Primera señal	Segunda señal
Moda	-1.21811695013305	-1.09132140636896
Mediana	-0.235222607973151	-0.0562785945094964
Valor cuadrático medio (RMS)	0.919893465271451	0.716597955960285
Valor medio cuadrático (SMR)	0.648032660149666	0.579300902216302
Rango	3.35058850508663	2.28321896364109
Media	0.0364844891186792	-0.0136812778829769
Varianza	0.848186096442096	0.515338494114583

Desviación estándar	0.920970193025863	0.717870806005219
Skewness	0.755854620629000	0.0648632349690846
Kurtosis	2.31614672998136	1.56643777127954
Quinto momento	3.20954648107546	0.218991681403461
Sexto momento	7.26352243763635	2.78069546816772
Factor de forma con RMS	1.21780157143524	1.12183364797958
Factor de forma con SMR	0.857898465056217	0.906895196959218
Factor de cresta	2.31817230522918	1.66327233752001
Factor de impulso	2.82307387616575	1.86591487398359
Factor latitud	3.29068530968960	2.05747574828925




Figura 3.13. Gráfica de barras para el tercer ancho de banda.

Como se puede observar en las tablas 3.2, 3.3, 3.4 y 3.5 y las Figuras 3.10, 3.11, 3.12 y 3.13 que, analizando todos los indicadores estadísticos, estos muestran valores muy diferentes en cada uno de los anchos de banda frecuencial de ambas señales, debido a esto, resulta importante analizar cada indicador estadístico con el objetivo de encontrar cual o cuales son los más discriminantes para encontrar cual pueda diferenciar entre dos diferentes tipos de señales.

Capítulo 4

Pruebas y resultados

4.1 Puesta de experimento

En la puesta del experimento se describe el procedimiento y métodos que se llevaron a cabo para obtener las señales EEG de los pacientes que conforman la base de datos, así como también algunos ejemplos de los estímulos que se presentaron a los pacientes durante el experimento.

Primeramente, los pacientes fueron sentados en una silla reclinable dentro de una habitación aislada con atenuación de sonido; y a un metro de distancia de la silla, una computadora donde se presentarán los estímulos/imágenes. Donde los estímulos se componen de un set de 90 imágenes de objetos, obtenidas del compendio de imágenes de Snodgrass & Vanderwart (1980), en las cuales cada de las imágenes seleccionadas, son una representación concreta de algún objeto y pueden ser fácilmente nombradas. Dichos estímulos/imágenes, se presentaron en un fondo blanco, con un tamaño de 5 – 10 cm de alto y 5 – 10 cm de ancho, obteniendo un ángulo visual de $0.05^\circ - 0.1^\circ$ aproximadamente. En la Figura 4.1, se muestra una representación aproximada de los sujetos durante el experimento, de igual forma, en la Figura 4.2 se muestran algunos ejemplos del set de imágenes que fueron utilizados como estímulos.



Figura 4.1. Representación aproximada de los sujetos durante el experimento (Marchesotti et al., 2016).




Figura 4.2. Ejemplos de las imágenes utilizadas como estímulos (Snodgrass & Vanderwart, 1980).

Posteriormente, para obtener una respuesta electrofisiológica del cerebro o ERP (por sus siglas, potencial relacionado a evento), se realizó una tarea de coincidencia de muestra diferida, en donde dos estímulos/imágenes (S1 y S2) aparecían en sucesión con un intervalo entre cada estímulo de 1.6 s. La duración del primer y segundo estímulo en cada prueba fue de 300 ms, y el intervalo en cada ensayo se fijó en 3.2 s. En donde la tarea de los sujetos, era decidir si la segunda imagen (S2) era la misma que la primera imagen (S1), se les pidió a los sujetos presionar una tecla de mouse con una mano si S2 era coincidente con S1, asimismo presionar una tecla de mouse con la otra mano si S2 era diferente de S1, después de la presentación de S2; a elección de las manos para elegir las situaciones coincidentes y no coincidentes se alternó en los sujetos. Finalmente, las señales fueron las que resultaron de ensayos sin ruido o frecuencias espurias, tanto para los casos coincidentes y no coincidentes.

4.2 Resultados

Como se describe en los pasos de la metodología propuesta, primeramente, es adquirida y leída las señales EEG de ambos grupos, pacientes sanos y

alcohólicos, provenientes de los 64 electrodos mencionados anteriormente. En el presente trabajo, se trabajó inicialmente con las señales de los 122 pacientes, donde cada uno tenía idealmente 120 pruebas, sin embargo, a causa de que algunas pruebas estaban incompletas o incluso vacías, se decidió trabajar con un banco de señales conformado por 10 pacientes sanos y 10 pacientes alcohólicos, en donde cada paciente tendría 10 pruebas cada uno, esto con el propósito de evitar errores y obtener resultados uniformes. Por lo tanto, se emplea un total de 200 pruebas, es decir 100 pruebas para el grupo de pacientes sanos y 100 pruebas para el grupo de pacientes alcohólicos.

Las Figuras 4.3 y 4.3 muestran un ejemplo de las señales provenientes del electrodo número 10 (F_{c6}), de un paciente sano y un alcohólico respectivamente, localizado en la zona central del cerebro.

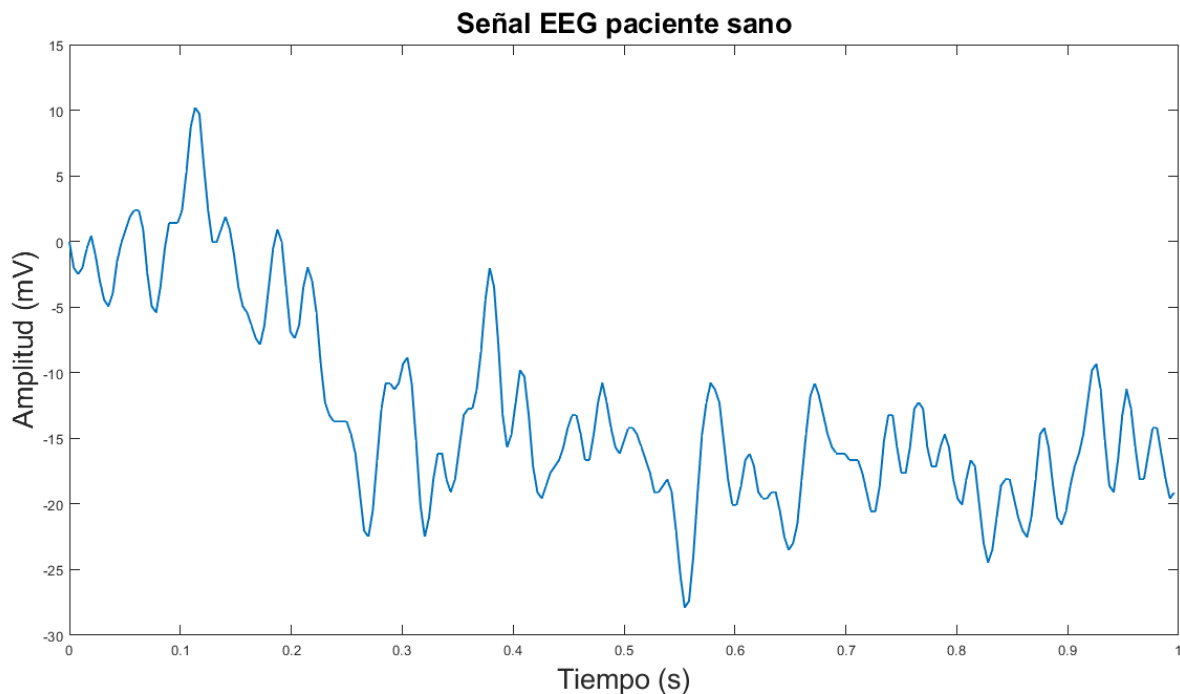


Figura 4.3. Señal proveniente del electrodo número 10 (F_{c6}) de un paciente sano.

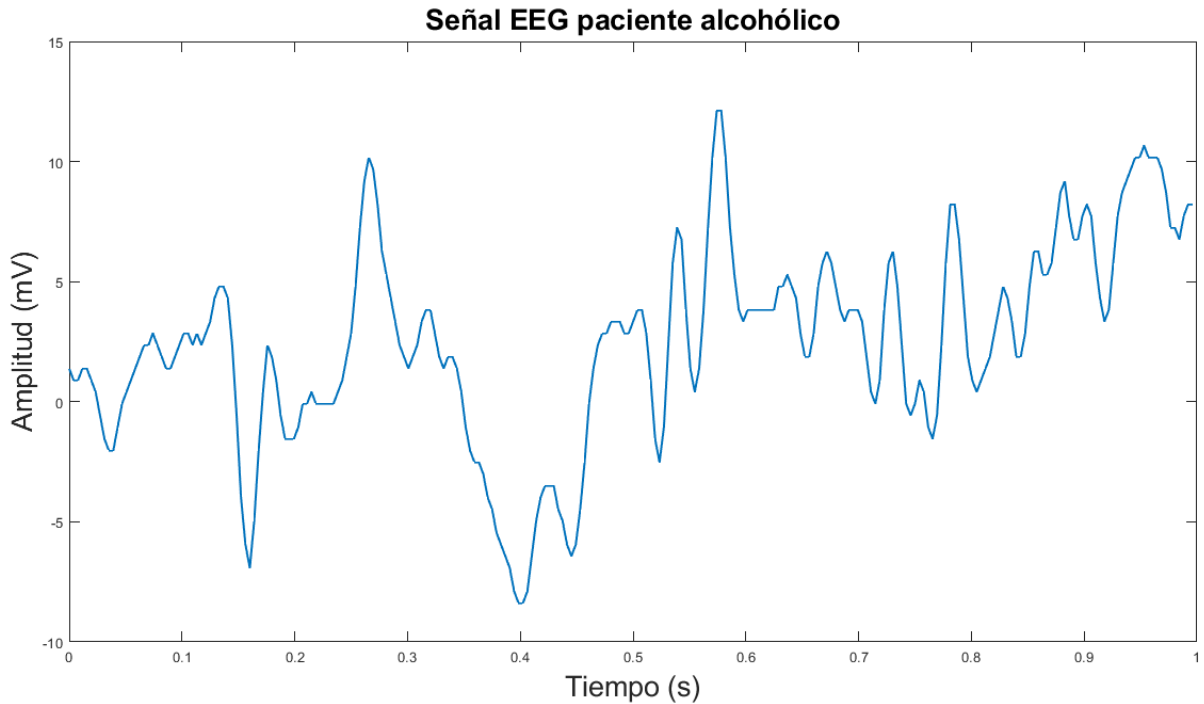



Figura 4.4. Señal proveniente del electrodo número 10 (F_{c6}) de un paciente alcohólico.

Analizando y comparando el comportamiento de las dos señales mostradas en las Figuras 4.3 y 4.4, no es posible resaltar o identificar algún fenómeno o característica que pueda ser asociado a la señal correspondiente, ya sea sano o alcohólico. Por tal motivo, resulta de gran importancia el preprocesar/analizar las señales esto con el objetivo de identificar características en las señales EEG que permiten ser asociadas al fenómeno estudiado. Para realizar esta tarea, las señales EEG de ambos grupos son analizadas y descompuestas en 10 bandas de frecuencia a través de la Descomposición de Modos Variacional, esto con el propósito de dividir las señales en anchos de banda de acuerdo a la información frecuencia contenida en las señales (Siuly et al., 2016), por otra parte, el seleccionar un valor menor podría implicar una falta de información frecuencia que conlleva en no encontrar características de interés en las bandas de frecuencia. Las Figuras 4.5 y 4.6 muestran las 10 descomposiciones o IMF (por sus siglas en inglés, Intrinsic Mode Function) provenientes del electrodo número 10 (F_{c6}), localizado en la zona central del cerebro, de un paciente sano. De igual manera, las Figuras 4.7 y 4.8

presentan las 10 IMFs resultantes del electrodo número 10 (F_{c6}), de un paciente alcohólico



[mvr3]

Figura 4.5. IMFs del nivel 1 al 5, del electrodo número 10 (F_{c6}) de un paciente sano.




Figura 4.6. IMFs del nivel 6 al 10, del electrodo número 10 (F_{c6}) de un paciente sano.




Figura 4.7. IMFs del nivel 1 al 5, del electrodo número 10 (F_{c6}) de un paciente alcohólico.




Figura 4.8. IMFs del nivel 6 al 10, del electrodo número 10 (F_{c6}) de un paciente alcohólico.

Continuando con el análisis de las bandas de frecuencia de los pacientes sanos y alcohólicos mostradas en las Figuras 4.5 a 4.8, es posible resaltar que, a causa de la complejidad de las señales, todavía no es posible distinguir algún patrón

o característica dentro de las bandas de frecuencia, que pueda ser asociada a su correspondiente categoría, ya sea sano o alcohólico, en otras palabras, no se encuentra alguna diferencia notable entre las IMFs de las señales de un paciente sano y las IMFs de un paciente alcohólico. Por tal motivo, es necesario una etapa adicional de procesamiento a las señales EEG, con el propósito de encontrar patrones o características que permitan asociarlas a su categoría correspondiente, que en este caso son las señales de pacientes sanos y alcohólicos. Por consiguiente y continuando con las etapas de la metodología propuesta, las señales descompuestas en bandas de frecuencia, a través de la Descomposición de Modos Variacional, a cada IMF (Intrinsic Mode Function), son analizadas a través de los indicadores estadísticos tales como: moda, mediana, valor cuadrático medio (RMS), valor medio cuadrático (SMR), rango, media, varianza, desviación estándar, skewness, Kurtosis, quinto momento, sexto momento, factor de forma con RMS, factor de forma con SMR, factor cresta, factor impulso y factor latitud.

Obteniendo las características resultantes de aplicar los indicadores estadísticos a cada una de las bandas de frecuencia, se procede a realizar un análisis estadístico de varianza, a través del método Kruskal Wallis, con el propósito de determinar cuál o cuáles de las bandas de frecuencia en conjunto con los indicadores de los 64 electrodos son los más discriminantes, es decir, que permitan la asociación de las señales EEG con un respectivo grupo: pacientes sanos y alcohólicos.

Posteriormente, un análisis detallado de los resultados obtenidos por el análisis estadístico Kruskal Wallis, se eligen las características más prometedoras, tomando como referencia el valor p (se eligen los valores que tienden a 0 ya que son las más discriminantes). De acuerdo con esto mencionado, se seleccionan cinco características que fueron las más discriminantes, las cuales son: la primer característica, consta del electrodo 60 (P_2), el indicador valor medio cuadrático y la IMF de nivel 5; la segunda característica está constituida por el electrodo 12 (F_{c2}), el indicador valor cuadrático medio y la IMF de nivel 6; la tercer característica está formada por el electrodo 60 (P_2), el indicador valor cuadrático medio y la IMF de

nivel 6; la cuarta característica la conforma el electrodo 25 (P_z), el indicador valor medio cuadrático y la IMF de nivel 6, y por último la quinta característica constituida por el electrodo 12 (F_{c2}), el indicador desviación estándar y la IMF de nivel 6. Las Figuras 4.9 a 4.13 muestran los resultados obtenidos con el método de Kruskal Wallis de las características más discriminativas. A su vez, la Tabla 4.1 muestra las características seleccionadas, junto con el electrodo, indicador estadístico y el valor de la IMF que la conforman, así como también el valor p de dicha característica. Como se puede observar en la tabla inferior, la descomposición o IMF de nivel 6 junto con los indicadores valor cuadrático medio y valor medio cuadrático, aparecen con mayor frecuencia, lo que sugiere que podría existir información frecuencial de interés que sea asociada para poder diferenciar entre las señales de los pacientes sanos y alcohólicos.

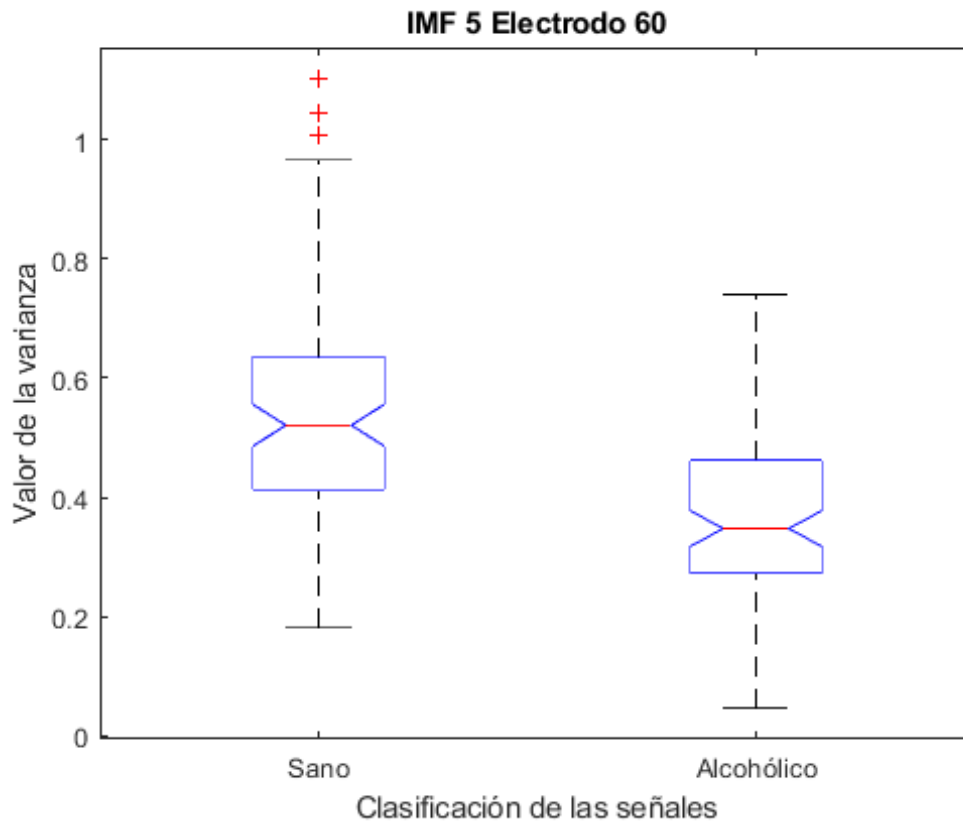


Figura 4.9. Diagrama de caja para la IMF 5, provenientes del electrodo 60 (P_2), para el indicador valor medio cuadrático.




Figura 4.10. Diagrama de caja para la IMF 6, provenientes del electrodo 12 (F_{c2}), para el indicador valor medio cuadrático.

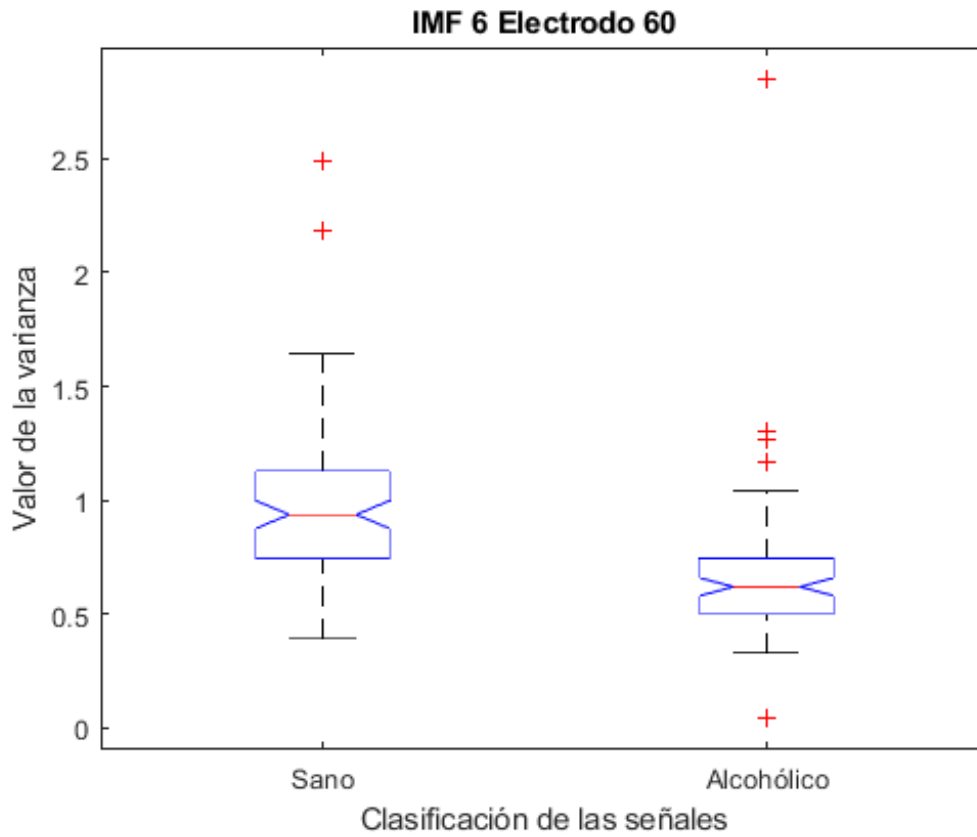


Figura 4.11. Diagrama de caja para la IMF 6, provenientes del electrodo 60 (P_2), para el indicador valor medio cuadrático.




Figura 4.12. Diagrama de caja para la IMF 6, provenientes del electrodo 25 (Pz), para el indicador valor medio cuadrático.




Figura 4.13. Diagrama de caja para la IMF 6, provenientes del electrodo 12 (F_{c2}), para el indicador valor medio cuadrático.

Tabla 4.1. Características más discriminantes conformadas por el electrodo, indicador estadístico y nivel de IMF.

Característica	Número de IMF	Electrodo	Indicador estadístico	Valor p
1	5	60 (P_2)	Valor medio cuadrático	3.217e-11
2	6	12 (F_{c2})	Valor cuadrático medio	1.747e-13
3	6	60 (P_2)	Valor cuadrático medio	7.408e-15
4	6	25 (P_2)	Valor medio cuadrático	1.101e-11

5	6	12 (F_{c2})	Desviación estándar	1.747e-13
---	---	-----------------	---------------------	-----------

Ya que se tienen las características seleccionadas conformadas por el nivel de descomposición, el electrodo y el indicador estadístico, para poder distinguir entre las señales de los pacientes sanos y alcohólicos, primeramente, se diseña una red neuronal multicapa, también conocida como perceptrón multicapa, en esta parte (etapa de entrenamiento), como se describe en el capítulo 2, la red neuronal trabaja con una parte de la base de datos, en el que ajusta los pesos o factores de ponderación de manera que las salidas del perceptrón multicapa se ajusten de acuerdo a sus entradas. Con ayuda de los diagramas de cajas mostrados en las Figuras 4.9 a 4.13 (70% de los datos o señales EEG), se crean vectores con 800 datos aleatorios, con 400 datos para cada categoría (sano y alcohólico), para poder entrenar al perceptrón multicapa y que ese sea capaz de clasificar las señales de los pacientes sanos y alcohólicos. Primeramente, se elige el número de capas ocultas en el perceptrón multicapa, en donde la literatura recomienda al menos el doble de número de capas de entrada (Lopez-Ramirez et al., 2016; Stathakis, 2009). Por lo tanto, en el presente trabajo se utilizó una red neuronal con 5 entradas, para las 5 características seleccionadas con ayuda del método Kruskal Wallis, un total de 10 neuronas en la capa oculta y 2 salidas, las cuales corresponden a las categorías de las señales, sano y alcohólico (esta configuración brinda los mejores resultados). Una vez entrenada la red neuronal, la siguiente etapa es evaluar (etapa de validación) su funcionamiento; por tal motivo, se valida la red neuronal con ayuda del 30% de información restante (30 pruebas por condición) de la base de datos que fue utilizada en este trabajo.

Para poder evaluar la eficacia de la red neuronal, se emplea una matriz de confusión, que sirve como herramienta estadística y permite hacer un análisis de productos vectoriales (López et al., 2018), en este sentido es utilizada para conocer el desempeño de la red neuronal, en donde se obtienen cuantas pruebas se clasificaron de manera correcta. La Tabla 4.2 muestra la matriz de confusión obtenida en este trabajo de tesis, además la ecuación (4.1) muestra la exactitud de

la clasificación, resultando en un 90%; por otra parte, la ecuación (4.2) indica la sensibilidad o tasa de verdaderos positivos, resultando en un 90%; asimismo la ecuación (4.3) señala la especificidad o tasa de verdaderos negativos, con un resultado de 90%. En la cual, analizando los resultados obtenidos, se puede considerar que, a pesar de que las características seleccionadas no arrojaron una exactitud del 100%, las características seleccionadas pueden ser utilizadas para ofrecer un diagnóstico con buena exactitud.

Tabla 4.2. Matriz de confusión

		Valor real		Exactitud
		Sano	Alcohólico	%
Predicción	Sano	27	3	90
	Alcohólico	3	27	90
Exactitud Total				90

$$Exactitud\ Total = \frac{27+27}{60} = 0.9 \quad (4.1)$$

$$Sensibilidad_{(tasa\ de\ verdaderos\ positivos)} = \frac{27}{30} = 0.9 \quad (4.2)$$

$$Especificidad_{(tasa\ de\ verdaderos\ negativos)} = \frac{27}{30} = 0.9 \quad (4.3)$$

4.3 Discusión de resultados.

Evaluando la exactitud total de la metodología, para poder clasificar la predisposición a pacientes a desarrollar alcoholismo, se obtiene una exactitud total promedio del 90%, analizando y evaluando los resultados es posible considerar que la metodología obtiene resultados prometedores, probablemente no es alcanzado una eficacia mayor a causa del número de pruebas, en donde la base de datos presentaba algunas dificultades en cuanto a pruebas faltantes o pruebas con error

en las señales, lo que provoca que las características seleccionadas probablemente no sean suficientes para realizar una red neuronal que obtuviera un porcentaje de clasificación mayor. Sin embargo, este trabajo de tesis trabaja con un banco mayor de datos en comparación con otros estudios en la literatura, por ejemplo Anuragi & Sisodia (2020) y Siuly et al. (2019) obtienen una eficiencia del 98.75% y 99.58%, respectivamente, no obstante los investigadores trabajan con un banco de datos de solo un paciente sano y un paciente alcohólico, cada uno únicamente con una prueba, lo que sugiere que la alta eficiencia sea atribuido al uso reducido del conjunto de datos. Por otra parte Anuragi & Singh Sisodia (2019) y Silva et al. (2020), obtienen eficacias del 99.17% y 95.68%, respectivamente, demostrando resultados muy prometedores, sin embargo las metodologías llevadas a cabo por dichos autores, son metodologías de alta complejidad computacional, contribuyendo a la alta eficacia demostrada. Asimismo, este trabajo de tesis arroja resultados similares a Purnamasari et al. (2017) con una eficacia del 90% en donde también fue utilizado como clasificador una red neuronal; también Acharya et al., (2012) obtienen una eficacia del 91.7% con una alta carga computacional; incluso mejores resultados que Rachman et al., (2017) que obtuvieron una eficacia del 85%, con una carga computacional similar a la de este trabajo de tesis. Además, es preciso tener en cuenta, que como se mencionó en el apartado de antecedentes, este trabajo busca implementar otra metodología a nivel local, para el diagnóstico de personas con predisposición al alcoholismo mediante el análisis de señales fisiológicas del ser humano.

Capítulo 5

Conclusiones y Perspectivas.

5.1 Conclusiones

Cuando una persona presenta un consumo de alcohol frecuente, fuera de control e incluso problemático, existe una alta probabilidad que llegue a tener una condición médica relacionada con el consumo, dependencia o adicción de alcohol, la cual generalmente se caracteriza por la incapacidad de la persona para detener o incluso controlar su consumo de alcohol, a pesar también, de la situación del medio que lo rodea, es decir, condición social, laboral o también las consecuencias de salud que podría tener. Son múltiples las consecuencias para la salud que conlleva el abuso del alcohol, que van desde el corto plazo tales como accidentes automovilísticos, violencia, intoxicación por consumo; hasta largo plazo afectando órganos y sistemas del cuerpo humano, por ejemplo, cerebro, corazón, hígado, páncreas, sistema inmunológico, sistema gastrointestinal e incluso a desarrollar cáncer (WHO, 2018). Como es evidente, un oportuno diagnóstico en personas con predisposición a desarrollar alcoholismo, mejoraría la calidad de vida de las personas e incluso la de terceros, de manera que se evitan las consecuencias que fueron mencionadas anteriormente. Debido a la dificultad con respecto a la detección de la predisposición a desarrollar alcoholismo a través de cuestionarios, terapia u otras estrategias (Díaz-Anzaldúa et al., 2011), en este sentido, el análisis de las señales fisiológicas es un área de oportunidad, de manera que permita, a través de técnicas de procesamiento, asociarlas al fenómeno estudiado que en este caso en particular, es identificar la predisposición de pacientes a desarrollar alcoholismo, y que estos puedan tomar acciones de prevención disminuyendo el riesgo de afectar su calidad de vida.

En este trabajo de tesis se desarrolló una metodología de baja complejidad computacional, con el propósito de distinguir pacientes con predisposición a desarrollar alcoholismo a través de señales EEG provistas en la base de datos de acceso libre creada por Henri (1999), en donde se presentan señales EEG tanto de pacientes sanos como de alcohólicos. En este sentido, las señales EEG son primeramente descompuestas en sus diferentes bandas de frecuencia a través del método de descomposición de modos variacional. En cada una de las bandas de frecuencia fueron evaluados múltiples indicadores estadísticos, tales como

varianza, desviación estándar, Kurtosis, valor cuadrático medio, etc., con el fin de poder encontrar características que permitan diferenciar entre las señales de los pacientes sanos o de control y alcohólicos. Posteriormente, se realiza un análisis de varianza, donde el método estadístico Kruskal Wallis se empleó para estimar cuales son las características más discriminantes, de cada conjunto de valores conformados por el nivel de descomposición, electrodos y los indicadores estadísticos, para poder detectar a las personas con predisposición al alcoholismo. Para poder clasificar las señales, se entrenó y diseñó una red neuronal multicapa, en la cual, con ayuda de las características seleccionadas a través del método Kruskal Wallis, se utilizaron como variables de entrada del clasificador para poder distinguir de manera automática a personas con predisposición a desarrollar alcoholismo y personas sanas.

Los resultados obtenidos de la clasificación de la red neuronal, muestran que se obtuvo una eficiencia del 90% para distinguir entre ambos grupos, como se muestra en la matriz de confusión de la Tabla 4.2. Es de suma importancia mencionar que se obtiene una eficiencia buena o prometedora con una base de datos pequeña; por lo tanto, es importante realizar un análisis con más datos para obtener resultados más a profundidad y obtener una eficiencia que contemple más señales de la metodología propuesta. Sin embargo, en comparación con otros estudios donde obtienen una eficiencia mayor presentan una mayor complejidad computacional, en comparación con la metodología desarrollada en el presente trabajo, donde el objetivo inicial es que fuera de baja complejidad computacional. De igual forma, en cuanto a las investigaciones hechas a nivel local, se han propuesto diversos trabajos referentes al diagnóstico de enfermedades (Cruz Ramírez, 2018; Vargas Lopez, 2019; Vega Mancilla, 2016), en lo referido al diagnóstico de la predisposición de pacientes a desarrollar alcoholismo, este trabajo de tesis es una posible ruta para investigaciones futuras en el diagnóstico de la predisposición al alcoholismo a través de las señales EEG.

5.2 Prospectivas

Recordando lo mencionado en la sección de metodología, inicialmente se trabajó con un banco de señales de 122 pacientes, donde inicialmente cada paciente contenía 120 pruebas, sin embargo, a causa de que algunas pruebas presentaban errores o no tenían información, se decidió utilizar un banco de datos de 10 pacientes sanos y 10 pacientes alcohólicos, cada uno con solamente 10 pruebas; por lo tanto, se obtiene una eficiencia adecuada, pero es de suma importancia verificarla con otras señales EEG. Por lo que una alternativa, sería probar un banco de datos más grande, otra alternativa un poco complicada, sería realizar una base de datos propia, que sea más actualizada y estandarizada para reducir los errores durante los ensayos y de esta manera obtener señales uniformes; con el objetivo de corroborar la eficiencia de la metodología planteada en el trabajo de esta tesis.

Por otra parte, en la parte de procesamiento de las señales, una alternativa sería probar los diferentes algoritmos de clasificación que tiene el aprendizaje automático, por ejemplo, máquinas de vectores de soporte, análisis de componentes principales, árbol de decisiones, etc., ya que existe la posibilidad de que algún otro algoritmo se adapte mejor al fenómeno estudiado en este trabajo de tesis. Asimismo, para las características, quizás probar nuevos parámetros para la extracción de las características, como parámetros de Hjorth o fractales, por mencionar algunos. Donde finalmente se debe de conservar como objetivo una carga computacional baja, de manera que permita su implementación en hardware de bajo costo

Bibliografía.

- A Undarraga, J., & Venegas, R. (2005). *Introducción a Matlab*. Universidad Tecnológica de Chile. https://www.researchgate.net/publication/319101156_Introduccion_a_Matlab
- Abdullah, S. (2005). *Wavelet bump extraction (WBE) for editing variable amplitude fatigue loadings*. - *White Rose eTheses Online* [University of Sheffield]. <https://etheses.whiterose.ac.uk/10281/>
- Abdulrahman, S. A. (2019). Comparison between Alcoholic and Control Subjects in EEG signals Using Classification Methods. *Journal of Mechanics of Continua and Mathematical Sciences*, 14(4). <https://doi.org/10.26782/jmcms.2019.08.00008>
- Acevedo M, E., Serna A, A., & Serna M, E. (2017). Principios y características de las redes neuronales artificiales . En E. Serna M (Ed.), *Desarrollo e Innovación en Ingeniería* (2a ed., pp. 173–182). Instituto Antioqueño de Investigación. https://www.researchgate.net/profile/Edgar-Serna-M/publication/331385353_Desarrollo_e_innovacion_en_ingenieria_ed_2/links/5c76e4ce92851c69504663b5/Desarrollo-e-innovacion-en-ingenieria-ed-2.pdf
- Acharya, U. R., Hagiwara, Y., Deshpande, S. N., Suren, S., Koh, J. E. W., Oh, S. L., Arunkumar, N., Ciaccio, E. J., & Lim, C. M. (2019). Characterization of focal EEG signals: A review. *Future Generation Computer Systems*, 91, 290–299. <https://doi.org/10.1016/J.FUTURE.2018.08.044>
- Acharya, U. R., Sree, S. V., Chattopadhyay, S., & Suri, J. S. (2012). Automated diagnosis of normal and alcoholic EEG signals. *International journal of neural systems*, 22(3). <https://doi.org/10.1142/S0129065712500116>
- Antonioni, A. (2006). *Digital Signal Processing: Signals, Systems, and Filters*. McGraw Hill, 425–459. https://books.google.com/books/about/Digital_Signal_Processing.html?hl=es&id=JQ4fAQAIAAJ
- Anuragi, A., & Singh Sisodia, D. (2019). Alcohol use disorder detection using EEG Signal features and flexible analytical wavelet transform. *Biomedical Signal Processing and Control*, 52, 384–393. <https://doi.org/10.1016/J.BSPC.2018.10.017>
- Anuragi, A., & Sisodia, D. S. S. (2020). Empirical wavelet transform based automated alcoholism detecting using EEG signal features. *Biomedical Signal Processing and Control*, 57, 101777. <https://doi.org/10.1016/j.bspc.2019.101777>
- Ariza López, F. J., Rodríguez Avi, J., & Alba Fernández, M. V. (2018). Control estricto de matrices de confusión por medio de distribuciones multinomiales. *Geofocus: Revista Internacional de Ciencia y Tecnología de la Información*

Geográfica, ISSN-e 1578-5157, N^o. 21, 2018, 21, 215–226.
<https://doi.org/10.21138/GF.591>

Barchiesi, J. V. (2008). *Procesamiento Digital de Señales*.

Basogain Olabe, X. (2001). *Redes Neuronales Artificiales y sus Aplicaciones* (1a ed., Vol. 1).

Bermúdez Cicchino, A. (2013). *Técnicas de procesamiento de EEG para detección de eventos* [Universidad Nacional de La Plata].
<https://doi.org/10.35537/10915/32602>

Birbaumer, N. (2006). Brain-computer-interface research: Coming of age. *Clinical Neurophysiology*, 117(3), 479–483.
<https://doi.org/10.1016/J.CLINPH.2005.11.002>

Brzostowski, K., & Świątek, J. (2021). Dictionary adaptation and variational mode decomposition for gyroscope signal enhancement. *Applied Intelligence*, 51(4), 2312–2330. <https://doi.org/10.1007/S10489-020-01958-Z/TABLES/16>

Cabrera Sosa, B. B., & Rodríguez Sandoval, J. F. (2007). *Proceso de Diseminación del Modelo de Detección Temprana e Intervención Breve para Bebedores Problema en el IMSS* [Universidad Nacional Autónoma de México].
<https://raulmartindelcampo.files.wordpress.com/2016/11/manual-bebedores-problema.pdf>

Chan, Y., & Walmsley, R. P. (1997). Learning and Understanding the Kruskal-Wallis One-Way Analysis-of-Variance-by-Ranks Test for Differences Among Three or More Independent Groups. *Physical Therapy*, 77(12), 1755–1761.
<https://doi.org/10.1093/PTJ/77.12.1755>

Cruz Ramírez, H. (2018). *Metodología basada en la descomposición empírica de modos completa y fractales para la clasificación de la imaginación motora usando señales electroencefalográficas*. Universidad Autónoma de Querétaro.

Devore, J. L., & Berk, K. N. (2012). Overview and Descriptive Statistics. En *Modern Mathematical Statistics with Applications* (pp. 1–49). Springer, New York, NY.
https://doi.org/10.1007/978-1-4614-0391-3_1

Díaz-Anzaldúa, A., Díaz-Martínez, A., & Díaz-Martínez, L. R. (2011). The complex interplay of genetics, epigenetics, and environment in the predisposition to alcohol dependence. *Salud Mental*, 34(2), 157–166.
http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0185-33252011000200009&lng=es&tlng=en.

Dongare, A. D., Kharde, R. R., & Kachare, A. D. (2008). Introduction to Artificial Neural Network. *Certified International Journal of Engineering and Innovative Technology (IJEIT)*, 9001(1), 2277–3754.

Dragomiretskiy, K., & Zosso, D. (2014). Variational mode decomposition. *IEEE Transactions on Signal Processing*, 62(3), 531–544.
<https://doi.org/10.1109/TSP.2013.2288675>

- Echeverría San-Vicente, L., Ruiz Torres, G. M., Salazar Garza, M. L., Tiburcio Sainz, M. A., & Ayala Velázquez, H. E. †. (2008). *Manual de detección Temprana e Intervención Breve para Bebedores Problema*. <https://raulmartindelcampo.files.wordpress.com/2016/11/manual-bebedores-problema.pdf>
- El Bouchefry, K., & de Souza, R. S. (2020). Learning in Big Data: Introduction to Machine Learning. En *Knowledge Discovery in Big Data from Astronomy and Earth Observation: Astrogeoinformatics* (pp. 225–249). Elsevier. <https://doi.org/10.1016/B978-0-12-819154-5.00023-0>
- Electro-Cap International. (s/f). *Electro-Cap International Inc Archivos - Med Rent*. Recuperado el 22 de septiembre de 2022, de <https://medrent.mx/marca/electro-cap-international-inc/>
- Estrella, S. (2008). MEDIDAS DE TENDENCIA CENTRAL EN LA ENSEÑANZA BÁSICA EN CHILE. *Revista Chilena de educación matemática*, 4, 20–32.
- Franco Vergara, L. A. (2021). *Metodología para la identificación de predisposición al alcoholismo en personas mediante herramientas tiempo-frecuencia y machine learning usando señales EEG*. Universidad Autónoma de Querétaro.
- García Rodríguez, D. F., Ruiz Sanchiz, L. M., & Bisquerra Alzina, R. (2014). Consumo de alcohol en la adolescencia. Consideraciones médicas y orientaciones educativas ADOLESCENCIA Y CONSUMO DE ALCOHOL. En *Salud Mental* (Vol. 37).
- Ghorbani Afkhami, R., Azarnia, G., & Tinati, M. A. (2016). Cardiac arrhythmia classification using statistical and mixture modeling features of ECG signals. *Pattern Recognition Letters*, 70, 45–51. <https://doi.org/10.1016/J.PATREC.2015.11.018>
- Gómez Figueroa, L. J. (2016). Análisis de señales EEG para detección de eventos oculares, musculares y cognitivos [Universidad Politécnica de Madrid]. En *Universidad Politécnica de Madrid*. <http://oa.upm.es/44379/>
- Grabner, R. H., & De Smedt, B. (2012). Oscillatory EEG correlates of arithmetic strategies: A training study. *Frontiers in Psychology*, 3(OCT), 428. <https://doi.org/10.3389/FPSYG.2012.00428/BIBTEX>
- Gray, R. M., & Davisson, L. D. (2004). *An introduction to statistical signal processing* (Cambridge University Press (ed.); 1a ed.). Cambridge University Press.
- Gupta, V., Priya, T., Yadav, A. K., Pachori, R. B., & Rajendra Acharya, U. (2017). Automated detection of focal EEG signals using features extracted from flexible analytic wavelet transform. *Pattern Recognition Letters*, 94, 180–188. <https://doi.org/10.1016/J.PATREC.2017.03.017>
- Guyton, A. C., Hall, J. E., & Hall, M. E. (2017). *Guyton y Hall. Tratado de fisiología médica* (Elsevier (ed.); 13a ed.).
- Hassan, A. R., & Hassan Bhuiyan, M. I. (2016). Automatic sleep scoring using

- statistical features in the EMD domain and ensemble methods. *Biocybernetics and Biomedical Engineering*, 36(1), 248–255. <https://doi.org/10.1016/J.BBE.2015.11.001>
- Hecke, T. Van. (2012). Power study of anova versus Kruskal-Wallis test. *Journal of Statistics and Management Systems*, 15(2–3), 241–247. <https://doi.org/10.1080/09720510.2012.10701623>
- Henri, B. (1999). *EEG Database*. <https://archive.ics.uci.edu/ml/datasets/EEG+Database>
- Hu, H., Zhang, L., Yan, H., Bai, Y., & Wang, P. (2019). Denoising and Baseline Drift Removal Method of MEMS Hydrophone Signal Based on VMD and Wavelet Threshold Processing. *IEEE Access*, 7, 59913–59922. <https://doi.org/10.1109/ACCESS.2019.2915612>
- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Snin, H. H., Zheng, Q., Yen, N. C., Tung, C. C., & Liu, H. H. (1998). The empirical mode decomposition and the Hubert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 454(1971), 903–995. <https://doi.org/10.1098/rspa.1998.0193>
- Im, C.-H. (2018). *Basics of EEG: Generation, Acquisition, and Applications of EEG*. 3–11. https://doi.org/10.1007/978-981-13-0908-3_1
- Kannan, N., & Kundu, D. (2001). *STATISTICAL SIGNAL PROCESSING*.
- Kaur, C., Singh, P., & Sahni, S. (2019). Electroencephalography-Based Source Localization for Depression Using Standardized Low Resolution Brain Electromagnetic Tomography - Variational Mode Decomposition Technique. *European neurology*, 81(1–2), 63–75. <https://doi.org/10.1159/000500414>
- Kruskal, W. H., & Wallis, W. A. (1952). Use of Ranks in One-Criterion Variance Analysis. *Journal of the American Statistical Association*, 47(260), 583. <https://doi.org/10.2307/2280779>
- Kumar, Y., Dewal, M. L., & Anand, R. S. (2012). Features extraction of EEG signals using approximate and sample entropy. *2012 IEEE Students' Conference on Electrical, Electronics and Computer Science: Innovation for Humanity, SCEECS 2012*. <https://doi.org/10.1109/SCEECS.2012.6184830>
- Kumari, N., Anwar, S., & Bhattacharjee, V. (2020). Correlation and Relief Attribute Rank-based Feature Selection Methods for Detection of Alcoholic Disorder Using Electroencephalogram Signals. *IETE Journal of Research*. <https://doi.org/10.1080/03772063.2020.1780166>
- Lahmiri, S. (2016). A variational mode decomposition approach for analysis and forecasting of economic and financial time series. *Expert Systems with Applications*, 55, 268–273. <https://doi.org/10.1016/J.ESWA.2016.02.025>
- Liu, W., Cao, S., & Chen, Y. (2016). Applications of variational mode decomposition in seismic time-frequency analysis. <https://doi.org/10.1190/geo2015-0489.1>

81(5), V365–V378. <https://doi.org/10.1190/GEO2015-0489.1>

- Lopez-Ramirez, M., Ledesma-Carrillo, L., Cabal-Yepez, E., Rodriguez-Donate, C., Miranda-Vidales, H., & Garcia-Perez, A. (2016). EMD-Based Feature Extraction for Power Quality Disturbance Classification Using Moments. *Energies* 2016, Vol. 9, Page 565, 9(7), 565. <https://doi.org/10.3390/EN9070565>
- López Trigo, J. A., Martínez Álvarez, J. R. 1957-, Ramos Cordero, P., Redondo del Río, P., Camina Martín, A., Mateos Silleras, B. de, López Mongil, R., Niño Martín, V., Aranceta Bartrina, J. 1952-, Anibal Pérez Rodríguez, L. N., Espinosa Sánchez, R., Cicely, N., Contreras, L., Alfonso, D., Merchán, P., Branden, N., Gisela Pita Rodríguez, Beatriz Basabe Tuero C Santa Jiménez Acosta Lic Onay Mercader Camejo, D. C., Anderson, P., Gual, A., ... Molina, H. (2013). Alcohol y atención primaria de la salud Alcohol y atención primaria de la salud. *Organización Panamericana de la Salud Salud*, 274(1), 3–148. <https://doi.org/10.4067/S0718-85602009000300014>
- Mahmud, T., Khan, I. A., Mahmud, T. I., Fattah, S. A., Zhu, W. P., & Ahmad, M. O. (2021). Sleep Apnea Detection from Variational Mode Decomposed EEG Signal Using a Hybrid CNN-BiLSTM. *IEEE Access*, 9, 102355–102367. <https://doi.org/10.1109/ACCESS.2021.3097090>
- Malmivuo, J. (1995). Electroencephalography. *Bioelectromagnetism Principles and Applications of Bioelectric and Biomagnetic Fields*, 257–264. <https://doi.org/10.1093/ACPROF:OSO/9780195058239.003.0013>
- Marchesotti, S., Bassolino, M., Serino, A., Bleuler, H., & Blanke, O. (2016). Quantifying the role of motor imagery in brain-machine interfaces. *Scientific Reports*, 6. <https://doi.org/10.1038/SREP24076>
- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones Cátedra: Informática Aplicada a la Ingeniería de Procesos-Orientación I Redes Neuronales: Conceptos Básicos y Aplicaciones* (Vol. 1). <https://hopelchen.tecnm.mx/principal/sylabus/fpdb/recursos/r99867.PDF>
- Muralidhar Bairy, G., Niranjan, U. C., Oh, S. L., Koh, J. E. W., Sudarshan, V. K., Tan, J. H., Hagiwara, Y., & Ng, E. Y. K. (2017). Alcoholic index using non-linear features extracted from different frequency bands. *Journal of Mechanics in Medicine and Biology*, 17(7). <https://doi.org/10.1142/S0219519417400097>
- OMS(Organización Mundial de la Salud). (2018a, septiembre 21). *Alcohol*. <https://www.who.int/es/news-room/fact-sheets/detail/alcohol>
- OMS(Organización Mundial de la Salud). (2018b, septiembre 21). *El consumo nocivo de alcohol mata a más de 3 millones de personas al año, en su mayoría hombres*. <https://www.who.int/es/news-room/detail/21-09-2018-harmful-use-of-alcohol-kills-more-than-3-million-people-each-year--most-of-them-men>
- Padma Shri, T. K., & Sriraam, N. (2012). EEG based detection of alcoholics using spectral entropy with neural network classifiers. *2012 International Conference on Biomedical Engineering, ICoBE 2012*, 89–93.

<https://doi.org/10.1109/ICoBE.2012.6178961>

- Palaniswamy, U. (2005). Handbook of Statistics for Teaching and Research. En K. Palaniswamy & U. Palaniswamy (Eds.), *Plant and Crop Science*. New York: Food Products Press. <https://doi.org/10.1201/9781482277814>
- Pandey, P., & Seeja, K. R. (2022). Subject independent emotion recognition from EEG using VMD and deep learning. *Journal of King Saud University - Computer and Information Sciences*, 34(5), 1730–1738. <https://doi.org/10.1016/J.JKSUCI.2019.11.003>
- Perez-Sanchez, A. V., Perez-Ramirez, C. A., Valtierra-Rodriguez, M., Dominguez-Gonzalez, A., & Amezcua-Sanchez, J. P. (2020). Wavelet Transform-Statistical Time Features-Based Methodology for Epileptic Seizure Prediction Using Electrocardiogram Signals. *Mathematics 2020, Vol. 8, Page 2125*, 8(12), 2125. <https://doi.org/10.3390/MATH8122125>
- Piña Vega, R. (2019). *Metodología basada en dimensión fractal y lógica difusa para la predicción de infartos empleando señales ECG*. Universidad Autónoma de Querétaro.
- Purnamasari, P. D., Ratna, A. A. P., & Kusumoputro, B. (2017). Relative wavelet bispectrum feature for alcoholic EEG signal classification using artificial neural network. *International Conference on Quality in Research (QIR): International Symposium on Electrical and Computer Engineering*, 154–158. <https://doi.org/10.1109/QIR.2017.8168473>
- Quevedo, F. (2011). Medidas de tendencia central y dispersión. *Medwave*, 11(03). <https://doi.org/10.5867/MEDWAVE.2011.03.4934>
- Rachman, N. T., Tjandrasa, H., & Fatichah, C. (2017). Alcoholism classification based on EEG data using Independent Component Analysis (ICA), Wavelet denoising and Probabilistic Neural Network (PNN). *Proceeding - 2016 International Seminar on Intelligent Technology and Its Application, ISITIA 2016: Recent Trends in Intelligent Computational Technologies for Sustainable Energy*, 17–20. <https://doi.org/10.1109/ISITIA.2016.7828626>
- Rao, K. D., & Swamy, M. N. S. (2018). Digital signal processing: Theory and practice. *Digital Signal Processing: Theory and Practice*, 1–789. <https://doi.org/10.1007/978-981-10-8081-4>
- Ravi Kumar, M., & Srinivasa Rao, Y. (2018). Epileptic seizures classification in EEG signal based on semantic features and variational mode decomposition. *Cluster Computing 2018 22:6*, 22(6), 13521–13531. <https://doi.org/10.1007/S10586-018-1995-4>
- Sanei, S., & Chambers, J. A. (2007). EEG Signal Processing. En *EEG Signal Processing*. John Wiley & Sons Ltd,. <https://doi.org/10.1002/9780470511923>
- Sanei, S., & Chambers, J. A. (2013). EEG Signal Processing. En *EEG Signal Processing*. John Wiley and Sons. <https://doi.org/10.1002/9780470511923>

- Sazgar, M., & Young, M. G. (2019). EEG Artifacts. *Absolute Epilepsy and EEG Rotation Review*, 149–162. https://doi.org/10.1007/978-3-030-03511-2_8
- Schröder, M., Lal, T. N., Hinterberger, T., Bogdan, M., Hill, N. J., Birbaumer, N., Rosenstiel, W., & Schölkopf, B. (2005). Robust EEG channel selection across subjects for brain-computer interfaces. *Eurasip Journal on Applied Signal Processing*, 2005(19), 3103–3112. <https://doi.org/10.1155/ASP.2005.3103/METRICS>
- Serrano-Cuevas, G. (1977). *Estudio sobre la posibilidad de un posible diagnóstico precoz del alcoholismo* [Universidad Nacional Autónoma de México]. http://132.248.9.195/ptd2012/sin_sello/0677513/0677513_A1.pdf
- Shanbao, T., & Nitish V.Thankor. (2018). *Quantitative EEG Analysis Methods and Clinical Applications*.
- Silva, F. H. S., Medeiros, A. G., Ohata, E. F., & Reboucas Filho, P. P. (2020). Classification of Electroencephalogram Signals for Detecting Predisposition to Alcoholism using Computer Vision and Transfer Learning. *2020 IEEE 33rd International Symposium on Computer-Based Medical Systems (CBMS)*, 126–131. <https://doi.org/10.1109/CBMS49503.2020.00031>
- Siuly, S., Bajaj, V., Sengur, A., & Zhang, Y. (2019). An Advanced Analysis System for Identifying Alcoholic Brain State Through EEG Signals. *International Journal of Automation and Computing*, 16(6), 737–747. <https://doi.org/10.1007/s11633-019-1178-7>
- Siuly, S., Khare, S. K., Bajaj, V., Wang, H., & Zhang, Y. (2020). A computerized method for automatic detection of schizophrenia using EEG signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(11), 2390–2400. <https://doi.org/10.1109/TNSRE.2020.3022715>
- Siuly, S., Li, Y., & Zhang, Y. (2016). *EEG Signal Analysis and Classification* (1a ed.). Springer International Publishing. <https://doi.org/10.1007/978-3-319-47653-7>
- Smith, S. J. M. (2005). EEG in the diagnosis, classification, and management of patients with epilepsy. *Neurology in Practice*, 76(2), 2–7. <https://doi.org/10.1136/jnnp.2005.069245>
- Smith W., S. (1999). *The Scientist and Engineer's Guide to Digital Signal Processing* (Second). Edicions UPC. www.DSPguide.com
- Snodgrass, J. G., & Vanderwart, M. (1980). A standardized set of 260 pictures: Norms for name agreement, image agreement, familiarity, and visual complexity. *Journal of Experimental Psychology: Human Learning and Memory*, 6(2), 174–215. <https://doi.org/10.1037/0278-7393.6.2.174>
- Stathakis, D. (2009). How many hidden layers and nodes? *International Journal of Remote Sensing*, 30(8). <https://doi.org/10.1080/01431160802549278>
- Sweeney, K. T., Ward, T. E., & McLoone, S. F. (2012). Artifact removal in physiological signals-practices and possibilities. *IEEE Transactions on*

- Information Technology in Biomedicine*, 16(3), 488–500. <https://doi.org/10.1109/TITB.2012.2188536>
- Tan, L., & Jiang, J. (2013). Introduction to Digital Signal Processing. En L. Tan & J. Jiang (Eds.), *Digital Signal Processing* (Second). Academic Press. <https://doi.org/10.1016/B978-0-12-415893-1.00001-9>
- Theodorsson-Norheim, E. (1986). Kruskal-Wallis test: BASIC computer program to perform nonparametric one-way analysis of variance and multiple comparisons on ranks of several independent samples. *Computer methods and programs in biomedicine*, 23(1), 57–62. [https://doi.org/10.1016/0169-2607\(86\)90081-7](https://doi.org/10.1016/0169-2607(86)90081-7)
- Torre-Delgadillo, A., Estradas, J., & Ramos-Narváe, F. (2013). El tratamiento y costos de salud por año de pacientes mexicanos con cirrosis en el rubro clínico y endoscópico. *Endoscopia*, 25(4), 180–186. <https://www.elsevier.es/es-revista-endoscopia-335-pdf-X0188989313685369>
- Trejo Capula, O. J. (2014). *Reducción del consumo de alcohol a través de la aplicación del “Modelo de Detección Temprana e Intervención Breve para Bebedores Problema”*. Universidad Nacional Autónoma de México.
- Upadhyay, R., Padhy, P. K., & Kankar, P. K. (2015, febrero 3). Alcoholism diagnosis from EEG signals using continuous wavelet transform. *11th IEEE India Conference: Emerging Trends and Innovation in Technology, INDICON 2014*. <https://doi.org/10.1109/INDICON.2014.7030476>
- Urigüen, J. A., & Garcia-Zapirain, B. (2015). EEG artifact removal-state-of-the-art and guidelines. *Journal of neural engineering*, 12(3). <https://doi.org/10.1088/1741-2560/12/3/031001>
- Vargas Lopez, O. (2019). *Metodología basada en la EMD y medidas no lineales prevalentes en muerte súbita cardíaca*. Universidad Autónoma de Querétaro.
- Vargas Lopez, Olivia. (2022). *Detección de estrés en conductores automovilísticos a través de medidas estadísticas y señales electromiográficas* [Universidad Autónoma de Querétaro]. <http://ri-ng.uaq.mx/handle/123456789/3506>
- Vega Mancilla, S. G. (2016). *Procesamiento de imágenes termográficas en la detección de cáncer de mama* [Universidad Autónoma de Querétaro]. <http://localhost:8080/xmlui/handle/123456789/6011>
- Villatoro-Velázquez, J. A., Reséndiz, E. E., Mujica, S. A., Bretón-Cirret, M., Cañas-Martínez, V., Soto-Hernández, I., Fregosso-Ito, D., Fleiz-Bautista, C., Medina-Mora, M., Gutiérrez, J., Franco-Nuñez, A., Romero, M., & Mendoza, L. (2017). Encuesta Nacional de Consumo de Drogas, Alcohol y Tabaco. *Secretaría de Salud*, 1, 190. <https://www.gob.mx/salud%7Cconadic/acciones-y-programas/encuesta-nacional-de-consumo-de-drogas-alcohol-y-tabaco-encodat-2016-2017-136758>
- Walczak, S., & Cerpa, N. (2003). Artificial Neural Networks. En *Encyclopedia of Physical Science and Technology* (3a ed., pp. 631–645). Academic Press.

<https://doi.org/10.1016/B0-12-227410-5/00837-1>

WHO, G. (2018). *Global status report on alcohol and health 2018*.

Xia, Y., Gao, Q., & Ye, Q. (2015). Classification of gait rhythm signals between patients with neuro-degenerative diseases and normal subjects: Experiments with statistical features and different classification models. *Biomedical Signal Processing and Control*, 18, 254–262. <https://doi.org/10.1016/J.BSPC.2015.02.002>

Yanez-Borjas, J. J., Valtierra-Rodriguez, M., Camarena-Martinez, D., & Amezcua-Sanchez, J. P. (2020). Statistical time features for global corrosion assessment in a truss bridge from vibration signals. *Measurement*, 160, 107858. <https://doi.org/10.1016/J.MEASUREMENT.2020.107858>

Yazdani, A., & Setarehdan, S. K. (2007). Classification of EEG signals correlated with alcohol abusers. *2007 9th International Symposium on Signal Processing and its Applications, ISSPA 2007, Proceedings*. <https://doi.org/10.1109/ISSPA.2007.4555309>

Zhang, X. L., Begleiter, H., Porjesz, B., Wang, W., & Litke, A. (1995). Event related potentials during object recognition tasks. *Brain Research Bulletin*, 38(6), 531–538. [https://doi.org/https://doi.org/10.1016/0361-9230\(95\)02023-5](https://doi.org/https://doi.org/10.1016/0361-9230(95)02023-5)