

**Aplicación de la inteligencia
computacional en el análisis de datos
EEG para la clasificación y
reconocimiento de estados mentales
relacionados con mente divagante y
atención plena.**

Leonardo Montes Marin

Universidad de Caldas
Facultad de Ingenierías, Departamento de Sistemas (Centro de Bioinformática y Biología
Computacional de Colombia)
Manizales, Colombia
2022

Aplicación de la inteligencia computacional en el análisis de datos EEG para la clasificación y reconocimiento de estados mentales relacionados con mente divagante y atención plena.

Leonardo Montes Marin

Tesis o trabajo de investigación presentada(o) como requisito parcial para optar al título de:

Magister en Ingeniería Computacional

Director (a):

Ph.D. Luis Fernando Castillo Ossa

Codirector (a):

Ph.D. Gustavo Isaza Echeverri

Grupo de Investigación:

GITIR: Grupo de Investigación en Tecnologías de la Información y Redes

Línea de Investigación:

Modelos Biocomputacionales y Bioinformática - Inteligencia Computacional y Organizacional

Universidad de Caldas

Facultad de Ingenierías, Departamento de Sistemas (Centro de Bioinformática y Biología Computacional de Colombia)

Manizales, Colombia

2022

*Todo el honor y la gloria sean de nuestro Señor
Jesucristo. A. M. D. G.*

A mis Padres e Isabella

Agradecimientos

De manera especial presentar agradecimientos al Ph.D. Juan Diego Gomez, reconocido en la actualidad como uno de los principales neurocientíficos Colombianos a nivel internacional, quien estructuró el fundamento teórico desde la neurociencia, dirigió y orientó la formulación inicial de este proyecto a través del Centro de Bioinformática y Biología Computacional de Colombia en el marco del proyecto de regalías “Fortalecimiento de ciencia, tecnología e innovación en biotecnología para el departamento de Caldas apoyado por Infraestructura computacional avanzada y trabajo colaborativo” en conjunto con la Gobernación de caldas, mediante el programa Talento Innovador para Caldas Bioregion. Al programa de Maestría en Ingeniería Computacional de la Universidad de Caldas, al director Ph.D. Luis Fernando Castillo Ossa y codirector de Ph.D. Gustavo Isaza Echeverri por su apoyo académico y gran contribución a mi formación profesional, al personal docente y administrativo. Principalmente gracias a Dios y a mi familia por su apoyo permanente e incondicional durante toda mi carrera.

TÍTULO DE LA TESIS

Aplicación de la inteligencia computacional en el análisis de datos de electroencefalografía para la clasificación y reconocimiento de estados mentales relacionados con mente divagante y atención plena.

RESUMEN

La electroencefalografía EEG, se ha convertido en una herramienta de suma importancia en el análisis de la actividad cognitiva, las técnicas basadas en inteligencia artificial han llegado a integrarse como una parte fundamental en los procesos de extracción de patrones, clasificación y aprendizaje de datos de señales EEG. Uno de los fenómenos, objeto de estudio del análisis cerebral a nivel electrofisiológico y clínico es la meditación. Dado sus beneficios comprobados científicamente y su uso potencial para la curación de las condiciones médicas, relacionadas con trastornos cognitivos y el bienestar mental en general. Recientemente se han identificado un cúmulo de investigaciones que involucran recursos de la inteligencia computacional en el análisis de factores asociados al estudio de la mente divagante y la meditación. La meditación como herramienta reguladora de los pensamientos divagantes y su incidencia en la salud del cerebro, está fundamentada en el hecho de que algunos desordenes cognitivos vienen dados por los pensamientos divagantes. El estado de mente divagante se ve expresado mediante la actividad del Default-Mode Network DMN. La meditación regula el estado de DMN. Basados en estos principios se pretende diseñar un modelo e implementar un prototipo para la detección de la mente divagante MW, usando procesamiento de señales EEG y Aprendizaje Automático ML a partir de señales eléctricas producidas por el cerebro. Con el propósito de crear un framework basado en inteligencia artificial, para el análisis de datos EEG y caracterización de mente divagante MW, como base de un programa de entrenamiento asistido por computadora para el aprendizaje de la meditación.

Application from computational intelligence in EEG data analysis for mental states classification and detection involved in mind wandering and mindfulness.

ABSTRACT

Electroencephalography EEG has become in one main resources in cerebral activity analysis. Artificial Intelligence based techniques has been a fundamental part in pattern detection, classification and learning of EEG signals data. One of the subjects, which is object of study at electrophysiology and clinic level in neural analysis is meditation. Despite of its well-known and scientifically proven benefits and its potential use in medical conditions related with cognitive disorders and mental healthcare. At this point there are a few initiatives involved in the use of Computational Intelligence in the analysis of meditation. The meditation as mind-wandering controller and its relationship with mental wellness, is established in this project by the fact that some mental conditions are increased by mind-wandering MW; this experience arises from activity in the Default Mode Network DMN; Mindfulness meditation regulates the DMN activity. Based on these principles we propose to design a model and implement a prototype for mind-wandering MW classification using EEG signal processing and machine learning ML processing from electrical signals produced by the brain, with the purpose of create an Artificial Intelligence based framework to analyze EEG data and classify MW activity arousal, as a part of a computer-aided meditation training program.

ÍNDICE

Título de la tesis	1
Resumen.....	1
Abstract	2
Índice	3
Lista de Figuras.....	6
Lista de Tablas	8
Lista de Abreviaturas.....	11
1. CAPITULO 1. Introducción.....	13
1.1. Campo temático	13
1.2. Planteamiento del problema	14
1.2.1. Descripción de la realidad problemática.....	14
1.2.2. Formulación del problema	17
1.2.3. Delimitación de la investigación.....	18
1.3. Justificación	18
1.4. Objetivos:	21
1.4.1. Objetivo general.....	21
1.4.2. Objetivos específicos.....	21
1.5. Estructura del documento.....	21
2. CAPITULO 2. Revisión bibliográfica.....	22
2.1. Marco teórico.....	22
2.1.1. Procesamiento de Señales Bioeléctricas y Electroencefalografía:.....	22
2.1.2. Interfaces Cerebro Computador BCI	40
2.1.3. Procesamiento de señales EEG	42
2.1.4. Inteligencia Artificial y Aprendizaje Automático	63
2.2. Trabajos Relacionados.....	68
2.2.1. Mindwanering: La mente divagante y el Default Mode Network.....	68
2.2.2. Meditación Mindfulness: Una terapia de relajación de la mente basado en conciencia plena asociada y un fenómeno neurológico en la electroencefalografía,.....	71
2.2.3. Inteligencia Artificial y Aprendizaje automático en Interfaces Cerebro Computador	74
2.2.4. Interfaces Cerebro Computador en la actualidad	75
2.2.5. Teoría y métodos de estimación espectral: Aplicación al análisis EEG	75

2.2.6.	Referente neurocientífico de la mente divagante, la meditación y el DMN.....	83
3.	CAPITULO 3. Metodología: Descripción detallada del proceso	85
3.1.	Materiales y Métodos	85
3.1.1.	Establecer los datos provenientes de análisis neuronales con el fin de proyectar experimentos para la detección del Default Mode Network (DMN)	87
3.1.2.	Evaluar las técnicas de procesamiento de neuroseñales EGG para la detección de DMN a través de dispositivos BCI	88
3.1.3.	Determinar y aplicar técnicas de análisis de datos a partir de técnicas de clasificación y aprendizaje automático que aproximen la caracterización de mente divagante	93
3.1.4.	Validar el prototipo del sistema mediante pruebas que se llevaran a cabo sobre la interfaz	112
3.2.	Diseño de la solución.....	114
3.2.1.	Adquisición de datos	115
3.2.2.	Preprocesamiento y extracción de características.....	117
3.2.3.	Clasificación: Desarrollar un modelo predictivo	119
3.2.4.	Validación, optimizar del modelo y despliegue	121
4.	CAPITULO 4. Análisis de Resultados	123
4.1.	Estudio Entre-sujetos:	123
4.2.	Estudio Intra-sujetos:	125
5.	CAPÍTULO 5. Trabajo futuro, conclusiones y recomendaciones.....	129
5.1.	Diseñar un modelo e implementar un prototipo computacional, para la detección de estado de mente divagante, que contribuya en el aprendizaje de la meditación.	129
5.2.	Establecer los datos provenientes de análisis neuronales con el fin de proyectar experimentos para la detección del Default Mode Network (DMN).	129
5.3.	Evaluar las técnicas de procesamiento de neuroseñales EGG para la detección de DMN a través de dispositivos BCI.	129
5.4.	Determinar y aplicar técnicas de análisis de datos a partir de técnicas de clasificación y aprendizaje automático que aproximen la caracterización de mente divagante.	130
5.5.	Validar el prototipo del sistema mediante pruebas que se llevaran a cabo sobre la interfaz.	130
5.6.	Trabajo Futuro.....	130
	Anexos.....	131
	Anexo 1.....	131
	Anexo 2.....	131
	Anexo 3.....	131

Anexo 4.....	131
Anexo 5.....	131
Bibliografía / Referencias	132

LISTA DE FIGURAS

Ilustración 1	Posibilidad de riesgo de enfermedad mental.....	15
Ilustración 2	Grafico con las áreas más prominentes en la economía de la innovación en el 2018 (Silicon Valley Bank, 2018)	19
Ilustración 3	Ejemplo de Señal Bio eléctrica de Encefalograma	25
Ilustración 4	Ejemplo de señal bio eléctrica resultante de la estimulación.	25
Ilustración 5	Diagrama de bloques que describe los pasos principales del análisis de señales biomédicas. 26	
Ilustración 6	Ejemplo de una anotación manual de un ECG de 2 canales	28
Ilustración 7	Señales registradas de manera concurrente de una base de datos multimodal	29
Ilustración 8	La neurona, dendritas y axones	34
Ilustración 9	El córtex cerebral y sus 4 lóbulos. (Sörnmo & Laguna, 2005)	35
Ilustración 10	Detalle de los lóbulos cerebrales	36
Ilustración 11	Diferentes magnitudes de electroencefalografía	38
Ilustración 12	Sistema Internacional de posicionamiento de electrodos 10/20.....	40
Ilustración 13	Diagrama de Bloques BCI (Sörnmo & Laguna, 2005)	41
Ilustración 14	Modelamiento de EEG mediante filtro lineal de ruido blanco.....	49
Ilustración 15	Artefactos en EEG	52
Ilustración 16	Señal multicanal de EEG	53
Ilustración 17	Análisis espectral de un EEG con ritmo Alpha	57
Ilustración 18	La potencia espectral del EEG y sus parámetros relacionados	58
Ilustración 19	EEG mostrando el ritmo alpha.	61
Ilustración 20	Principios de segmentación de EEG	63
Ilustración 21	El Aprendizaje Automático es una de las subáreas de la inteligencia artificial	64
Ilustración 22	Tipos de aprendizaje en el aprendizaje automático.	67
Ilustración 23	La constelación de potencias de campo espectral medidas en un período de 3 minutos	70
Ilustración 24	Gráficos de perturbación espectral relacionada con eventos (ERSP).....	72
Ilustración 25	Regiones del cerebro involucradas en meditación de atención plena.	73
Ilustración 26	Técnicas clásicas y modernas de clasificación de algoritmos para BCI (Lotte et al., 2018a) .	75
Ilustración 27	Una descripción general de la estimación espectral para señales estacionarias y variables en el tiempo	76
Ilustración 28	El análisis espectral de múltitaper reduce el sesgo y la varianza en la estimación espectral .	79
Ilustración 29	Descripción detallada del flujo de trabajo de procesamiento y clasificación de señales EEG para mente divagante.....	86
Ilustración 30	Diagrama de Filtro CAR.....	91
Ilustración 31	Diagrama de grafico de cajas mostrando la distribución de las amplitudes	91
Ilustración 32	Grafico del comportamiento de la amplitud en función del tiempo.....	92
Ilustración 33	Visualización con EDFBrowser de la señal EEG en crudo	93
Ilustración 34	Espacio tangente de una matriz de covarianza C	98
Ilustración 35	Análisis discriminante lineal	105
Ilustración 36	Grafico de SVC con kernel lienal	106
Ilustración 37	función de decisión para un problema linealmente separable,.....	107
Ilustración 38	Función sigmoide logística estándar donde $L=1$, $K=1$, $x_0 = 0$	109
Ilustración 39	Perceptrón multicapa (MLP) de una sola capa oculta.	110
Ilustración 40	Comparativo de procesos de desarrollo para BCI y ML	115
Ilustración 41	Diagrama del diseño experimental y enfoque analítico.	117
Ilustración 42.	Número de épocas EEG asociadas a BF y MW	123
Ilustración 43.	Valores promedios de desempeño sobre los sujetos	124
Ilustración 44.	Diagramas críticos de diferencia entre los pares clasificador/característica	125

Ilustración 45. Ranking de desempeño para los diferentes modelos y características en la clasificación de BF y MW	126
Ilustración 46. Mapas post-hoc para evaluación de la diferencia estadística significativa	127

LISTA DE TABLAS

Tabla 1 Medidas de evaluación de rendimiento de un algoritmo de procesamiento de una señal	27
Tabla 2 Métricas generales de los datos EEG obtenidos mediante perfilamiento.....	91
Tabla 3 Algoritmo para promedio de matrices de covarianza	97
Tabla 4 Lista de técnicas de extracción de características	99
Tabla 5 Matriz de confusión para análisis de rendimiento en aprendizaje supervisado (Fawcett, 2006) ..	113
Tabla 6. Valores totales de sujetos, épocas de señales EEG de 5 segundos para BF y MW.	125
Tabla 7. Estadístico y p-valor de la prueba Kruskal-Wallis para cada una de las configuraciones en número de canales y rango de frecuencias.....	127

LISTA DE ECUACIONES

Ecuación 1.....	43
Ecuación 2.....	43
Ecuación 3.....	44
Ecuación 4.....	45
Ecuación 5.....	45
Ecuación 6.....	45
Ecuación 7.....	45
Ecuación 8.....	45
Ecuación 9.....	46
Ecuación 10.....	46
Ecuación 11.....	46
Ecuación 12.....	47
Ecuación 13.....	47
Ecuación 14.....	48
Ecuación 15.....	48
Ecuación 16.....	50
Ecuación 17.....	50
Ecuación 18.....	50
Ecuación 19.....	50
Ecuación 20.....	50
Ecuación 21.....	50
Ecuación 22.....	54
Ecuación 23.....	54
Ecuación 24.....	55
Ecuación 25.....	56
Ecuación 26.....	56
Ecuación 27.....	56
Ecuación 28.....	59
Ecuación 29.....	59
Ecuación 30.....	59
Ecuación 31.....	59
Ecuación 32.....	60
Ecuación 33.....	62
Ecuación 34.....	89
Ecuación 35.....	89
Ecuación 36.....	90
Ecuación 37.....	94
Ecuación 38.....	96
Ecuación 39.....	96
Ecuación 40.....	96
Ecuación 41.....	97
Ecuación 42.....	97
Ecuación 43.....	98
Ecuación 44.....	99
Ecuación 45.....	100
Ecuación 46.....	101
Ecuación 47.....	101

Ecuación 48.....	101
Ecuación 49.....	101
Ecuación 50.....	102
Ecuación 51.....	102
Ecuación 52.....	102
Ecuación 53.....	102
Ecuación 54.....	103
Ecuación 55.....	103
Ecuación 56.....	105
Ecuación 57.....	105
Ecuación 58.....	105
Ecuación 59.....	107
Ecuación 60.....	108
Ecuación 61.....	111
Ecuación 62.....	111
Ecuación 63.....	111

LISTA DE ABREVIATURAS

DMN: Red de modo predeterminado (Default Mode Network,)

EEG: Electroencefalografía.

fMRI: Resonancia Magnética Funcional.

PET: Espectrografía por Emisión de Positrones.

WHO: World Health Organization.

OMS: Organización Mundial de la Salud.

DALY: Disability Adjusted Life Years.

BCI: Interfaz Cerebro Computador (Brain Controller Interface)

IA: Inteligencia Artificial

AA: Aprendizaje Automático

ML: Machine Learning

TFF: transformada rápida de Fourier

DTF: Transformada discreta de Fourier

RNN: Redes Neuronales Recurrentes

ANN: Redes neuronales Artificiales (Artificial Neural Network)

SNC: Sistema Nervioso Central

SNP: Sistema Nervioso Periférico

PE: Potencial Evocado

PDF: Función de densidad de probabilidad

EOG: Electrooculograma

EMG: Electromiografía

ECG: Electrocardiograma

DTFT: Transformada de Fourier discreta en tiempo

FFT: Transformada rápida de Fourier

SPI: Índice de pureza espectral

ICA: Análisis de Componentes Independientes (Independent Component Analysis)

ASR: Reconstrucción del Subespacio de artefactos (Artifact Subspace Reconstruction)

CAR: Common Average Reference (Spatial Filter)

CSP: Patron Comun Espacial (Common Spatial Pattern)

LDA: Análisis Discriminante Lineal (Linear Discriminant Analysis)

SVM: Maquina de Soporte Vectorial (Support Vector Machine)

SVC: Clasificadores por Vectores de Soporte (Support Vector Classifier)

MLP: Perceptrón multicapa (Multi-layer Perceptron.)

LR: Regression Logística (Logistic Regression)

ERP: Potenciales Evocados Relacionados (Evoked Related Potentials)

CNN: Red Neuronal Convolutacional Profunda

DFA: Análisis de fluctuación de desviación de tendencia (Detrended Fluctuation Analysis)

PFD: Dimensión fractal Petrosiana (Petrosian Fractal Dimension)

HFD: Dimensión Fractal de Higuchi (Higuchi Fractal Dimension)

SVD: Entropía de Descomposición de valores Singulares (Singular Value Decomposition)

ApEn : Entropía aproximada (Approximate entropy)

MW: Mente Divagante (Mind Wandering)

BF: Concentración en la respiración (Breath Focus)

BS: Sonido de Campana BS (Bell Sound)

1. CAPITULO 1. INTRODUCCIÓN

1.1. Campo temático

Dado el creciente aumento en el uso de tecnologías de alto impacto, como la **Inteligencia Artificial** y dentro de esta disciplina, el **Aprendizaje Automático**, Se proyecta el estudio del cerebro como otra de las aplicaciones donde la IA podría desempeñar un rol importante en diversas áreas como rehabilitación, computación afectiva, robótica, juegos y **neurociencia**. El cerebro es un mecanismo complejo en todos los niveles de abstracción, desde la ciencia médica hasta la ingeniería, y la neurociencia pretende dar explicación a un amplio espectro de dinámicas llevadas a cabo en este órgano que coordina todas las actividades relacionadas con la función cognitiva del ser humano.

Numerosos métodos para la captura de la actividad neuronal han sido desarrollados, tanto los basados en señales metabólicas como la resonancia magnética funcional fMRI o La espectrografía por emisión de positrones PET, entre otros y a nivel de señales eléctricas y magnéticas tenemos la magneto-electroencefalografía MEG, pasando por métodos invasivos como los electrodos intra neurales, llegando a los mas difundidos, dada su relativa baja complejidad respecto a los demás, como es la **Electroencefalografía EEG**.

Con el fin de lograr una adecuada interpretación de los datos que se obtienen del cerebro, se implementan técnicas basadas en modelos matemáticos, como el **Procesamiento de Señales EEG**, con los cuales es posible realizar, el preprocesamiento, limpieza, segmentación e identificación de factores asociados a la frecuencia, el espectrograma y la amplitud de las ondas cerebrales. Estas señales eléctricas que constantemente incorporan metodologías de procesamiento más robustas son empleadas por las **Interfaces Cerebro Computador BCI** para identificar los patrones del cerebro relacionados con la ejecución de comandos o la relación con ciertas actividades mentales.

Desde la perspectiva de **la Ingeniería Computacional** y el **Desarrollo de Software** la implementación y apropiación de librerías estructuradas, generalmente de código abierto junto con otras herramientas informáticas soportan la investigación desde el enfoque de analíticas de datos en neurociencia.

Este trabajo pretende implementar y analizar algoritmos computacionales basados en diferentes arquitecturas para el procesamiento y clasificación de neuro señales que han sido obtenidas mediante un protocolo de experimentación para detectar mente divagante MW y meditación basada en la respiración BF.

1.2. Planteamiento del problema

1.2.1. Descripción de la realidad problemática

Según la Organización Mundial de la Salud OMS (World Health Organization WHO) los desórdenes mentales, principalmente la depresión y demás trastornos asociados como bipolaridad, esquizofrenia, demencia, entre otros, han sido catalogados entre los mayores riesgos a la salud a nivel global, a los que conllevan efectos altamente negativos en el campo del comportamiento, la calidad de vida, la salud y la economía. Encontrándose entre las 10 principales causas de incapacidad junto con la dependencia de alcohol y el abuso de sustancias; En la actualidad la depresión es una de las patologías mentales más comunes alrededor del mundo, con más de 350 millones de afectados; en países con economías estables, los desórdenes mentales consumen más del 20% de los costos de servicios de salud y en cerca de 20 años, será el desorden mental con las repercusiones más significativas tanto social como económicamente (WHO, 2009; World Health Organization, 2015).

La depresión es un desorden mental que se presenta con bajo estado de ánimo, falta de interés o placer, disminución de la energía, sentimientos de culpa o baja autoestima, actividad del sueño interrumpida, falta de apetito y baja capacidad de concentración. Más allá de que la depresión algunas veces conlleva síntomas de ansiedad. Estos problemas pueden ser crónicos o recurrentes y llevar a limitaciones en la capacidad de una persona para llevar las responsabilidades diarias. Inclusive llevando al suicidio. Según recientes estadísticas de la OMS se presenta alrededor de un millón de suicidios al año, y por cada suicidio completado, veinte o más personas lo han intentado.

La marginalización histórica de la salud mental en los principales servicios de salud y asistencia social en muchos países ha contribuido a una estigmatización endémica y discriminación de las personas mentalmente enfermas. Esto también significa que la salud mental ha recibido una prioridad baja en la mayoría de las agendas con consecuencias en los presupuestos, planeación de políticas y desarrollo de servicios. La estimación de la carga mundial, de la enfermedad con discapacidad, ajustada a los años de vida (Disability Adjusted Life Years DALYs¹) muestra que las condiciones mentales y neurológicas se encuentran entre los principales aportantes a la medida implementada por la OMS. Para principios de este siglo se contabilizaba el 11% de la pérdida del DALYs debido a todas las enfermedades y trastornos. Entre todos los desórdenes mentales y neurológicos, la depresión cuenta con la más alta proporción de la carga. Casi en cualquier lugar del mundo la prevalencia de la depresión es el doble en mujeres que en hombres. Otros cuatro desórdenes mentales figuran en las 10 principales causas de incapacidad o inhabilidad en el mundo, estas son abuso de alcohol, desorden bipolar, esquizofrenia y trastorno obsesivo compulsivo. La cantidad de personas con desórdenes mentales y neurológicos crecerá hasta ocupar el 15% de la pérdida del DALY al año 2020 y será la segunda causa de incapacidad a nivel mundial. Se espera que sea uno de los más grandes contribuyentes a la carga de enfermedades. (World Federation For Mental Health (WFMH), 2012; World Health Organization, 2001, 2012).

¹ Disability-adjusted life years (DALYs) DALYs son una tasa común con la que se pueden medir las muertes a diferentes edades y la discapacidad. Un DALYs se puede considerar como un año perdido de vida "saludable", y la carga de la enfermedad se puede considerar como una medida de la brecha entre el estado de salud actual y una situación ideal en la que todos viven hasta la vejez, libres de enfermedades y discapacidad. Los DALYs para una enfermedad o lesión se calculan como la suma de los años de vida perdidos debido a la mortalidad prematura (AVP) en la población y los años perdidos por discapacidad (YLD) para los casos incidentes de la enfermedad o lesión.

Estos trastornos no discriminan raza, nacionalidad, estrato socioeconómico y en pocos casos edad, una de cada diez personas sufre de depresión severa y casi una de cada cinco personas ha sufrido este desorden durante su vida. Ante las recientes crisis económicas presentadas alrededor del mundo, la OMS ha realizado un estudio a nivel del territorio europeo que demuestra una relación directa entre el riesgo de padecer enfermedades mentales y el número de deudas, lo que demuestra que estos padecimientos pueden ser eventualmente adquiridos a lo largo de la vida como en la adversidad, traumas infantiles y situaciones de estrés, con una contribución sustancial de ser contraídos genéticamente.

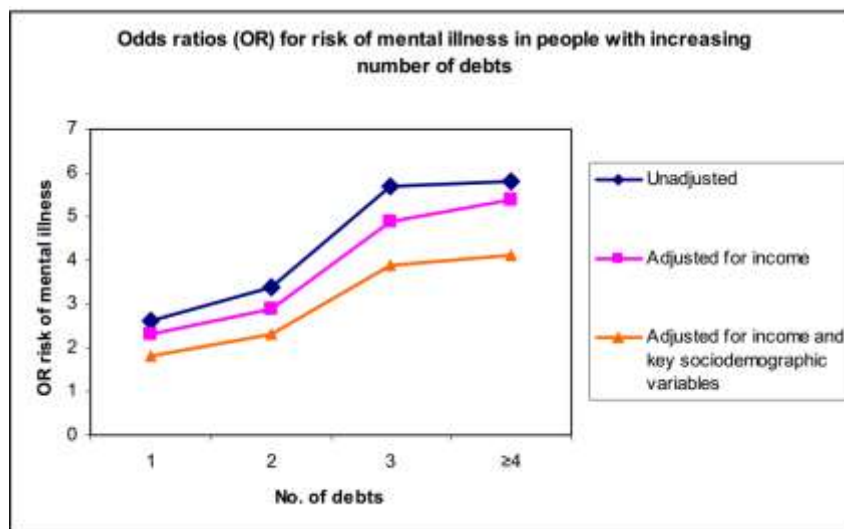


Ilustración 1 Posibilidad de riesgo de enfermedad mental en personas con incrementos en el número de deudas. *(Wahlbeck et al., 2011)*

En general, el marco de soluciones para los trastornos mentales en general varía desde los pacientes tratados con medicinas antidepresivas que continúan presentando una baja efectividad. Por otra parte, la estimulación magnética transcraneal resulta ser otro de los tratamientos en casos severos de depresión a pesar de las contraindicaciones a nivel de seguridad y su eficiencia aparentemente desconocida, otros enfoques se han presentado desde la medicina alternativa e inclusive desde la medicina ancestral con el uso de la ayahuasca o la planta de coca, practicada por algunas culturas indígenas en Colombia y América Latina. Esto, sin contar el costo de recibir un tratamiento médico psiquiátrico especializado que puede llegar a ser alto. A la luz de esta, la psicoterapia ofrece una alternativa no invasiva con notables efectos y amplia aceptación. Este trabajo es pionero como un enfoque técnico al mindfulness², desde una terapia basada en meditación que podría aplicarse en personas que sufren de una variedad de condiciones psicológicas dadas por la presencia de pensamiento divagantes.

² El objetivo es lograr un profundo estado de conciencia durante la sesión, y se usan varias técnicas concretas para alcanzarlo. Perseguimos conseguir que nuestra conciencia se relaje y no elabore juicios de nuestras sensaciones, sentimientos o pensamientos. Saber qué acontece en nuestro fuero interno en cada instante a través de la gestión de los procesos atencionales. El Mindfulness consigue separar la persona de sus pensamientos para poder reconocerlos y poner en duda los patrones mentales, otorgando un gran peso al aquí y el ahora mediante una atención total al momento presente.

Los beneficios psicoterapéuticos de la meditación y el mindfulness han sido avalados científicamente en muchos trabajos a nivel mundial, considerándola una forma natural de reducir los niveles de estrés, depresión, entre otros trastornos mentales. Visto como una actividad intelectual el mindfulness busca saber qué acontece en nuestro cuerpo interno en cada instante a través de la gestión de los procesos atencionales. Sin embargo, la meditación mediante el seguimiento consciente de la respiración o la concentración en un aspecto de la percepción mental, son procesos que requieren largos periodos de entrenamiento para aprender a evitar la denominada desviación de la atención(Lomas et al., 2015b).

El mindfulness y otras formas de meditación están recibiendo una gran atención por parte de la comunidad científica, existe un conocimiento limitado acerca de modelos experimentales de la práctica de la meditación llevados a mecanismos comunes de la psicología y la neurociencia. Los centros de investigación y sus colaboradores se encuentran en proceso de desarrollo de nuevos enfoques que fusionen la relación entre las perspectivas de la meditación contemplativa y la teoría científica con el fin de realizar mejores hipótesis acerca de los efectos de la práctica de la meditación en el cuerpo, el cerebro, la mente y el comportamiento humano. El centro para mentes saludables, Center for Healthy Minds, de la Universidad de Wisconsin, en cabeza del reconocido Dr. Richard J. Davidson y el monje budista Matthieu Ricard, vienen adelantando un gran número de investigaciones relacionadas con el entendimiento del bienestar mental en general desde un enfoque científico a partir del estudio del mindfulness; el control cognitivo en la regulación de emociones, atención y dolor; el estudio de la conciencia; la neurobiología de la regulación del stress; el riesgo de depresión ante eventos traumáticos, hasta el análisis del mindfulness a través de la práctica contemplativa budista (Center for Investigating Healthy Minds, 2015).

La bioingeniería y la ingeniería biomédica han dedicado parte de sus esfuerzos al estudio del ejercicio contemplativo y la meditación, estudiando la dinámica neuronal, los cambios fisiológicos, la medición eléctrica, los cambios espectrales, y el análisis de las señales. Particularmente en el ámbito de la ingeniería computacional existen aun relativamente pocas iniciativas que involucren el uso de técnicas propias de la inteligencia artificial relacionadas con la meditación psicoterapéutica, entre ellas: AURA(Aura Health, 2017) la cual permite realizar un seguimiento a la evolución al aprendizaje de la meditación mediante microciclos programados asistido por IA mediante una app móvil. Respecto al uso de Machine Learning en electroencefalografía para fenómenos de meditación, más allá de WellBrain,(Maniar et al., 2017) la cual comprende una innovadora propuesta para el alivio del dolor crónico mediante meditación, sin embargo, este proyecto carece de una referencia más amplia, al estar basada solamente en el análisis de un dispositivo EEG con tan solo un electrodo (Interfaz NeuroSky), ubicado en la región pre frontal de la cabeza. Hasta donde la fase exploratoria de este proyecto ha evidenciado, aún no han sido patentadas herramientas que involucren el análisis de la actividad cerebral durante la meditación en tiempo real mediante un dispositivo que realice mediciones a nivel de electroencefalografía con más de un electrodo.

La inteligencia artificial y el aprendizaje automático recientemente han comenzado a jugar un papel cada vez más preponderante en la innovación de diversos ámbitos de la vida diaria, en la salud con mecanismos que realizan diagnósticos a partir de los datos del paciente o reconocimiento de imágenes médicas; la seguridad informática con la prevención de inyección de malware ; el transporte con la circulación de automóviles autónomos sin necesidad de conductor; los negocios con la creación de agentes de chat robóticos que están en capacidad de realizar atención al cliente o realizar la venta de un producto o servicio; por mencionar solo algunas aplicaciones. Según los

portales y medios especializados en negocios y tecnología se espera que este mercado continúe creciendo a niveles exponenciales con ingresos estimados de 36 billones de dólares al año 2025 (Silicon Valley Bank, 2018).

Según la Organización Mundial de la Salud, La depresión y otros trastornos son desordenes que pueden ser diagnosticados fielmente y tratados por personal no especializado como parte de una medida primaria en atención en salud, sin embargo, la mayoría de las personas que los padecen no reciben la atención adecuada (World Health Organization, 2012). Lo que implica la idoneidad de hacer uso de mecanismos computacionales asistidos por inteligencia artificial como herramientas orientadas al aprendizaje de la meditación, visto en el marco de una actividad suplementaria en el tratamiento psicoterapéutico de trastornos mentales, contribuyendo así al mejoramiento del sistema de atención primaria en salud para pacientes con trastornos mentales. En este trabajo se propone un sistema inteligente que detecta la desviación de la atención y generar un prototipo de un mecanismo asistido por computador orientado al aprendizaje de la meditación.

1.2.2. Formulación del problema

Respondiendo al cuestionamiento acerca de ¿Qué se va a investigar?, se determina que la formulación del problema está enmarcada en el hecho de identificar, como aplicar Aprendizaje Automático u otras técnicas propias de la Inteligencia Artificial, en el análisis de datos provenientes de registros de electroencefalografía y comprobar si es posible realizar clasificación de estados mentales relacionados con el Mindfulness o la mente divagante a través de su expresión en el Default Mode Network. Llevando a cabo un análisis de datos que involucre técnicas de análisis computacional, con el fin de elaborar un prototipo que sirva como herramienta, en el aprendizaje de la meditación. Dicha actividad, vista como un ejercicio mental, consiste en breves palabras, en evitar la desviación de la atención plena y consciente. Esta herramienta también se perfila en un futuro, desde un enfoque terapéutico hacia la meditación, como una medida de atención primaria e inclusive remotamente asistida (tele asistida) al tratamiento de algunos desordenes y trastornos mentales.

1.2.2.1. Problema general

El Problema General de esta investigación recae sobre la pregunta acerca de ¿Cómo utilizar aprendizaje automático para caracterizar estados mentales, relacionados con mente divagante y el mindfulness, orientado al aprendizaje de la meditación, utilizando datos con origen en muestras de electroencefalografía?

1.2.2.2. Problemas específicos

Problema Específico 1: ¿Cómo realizar la obtención y extracción de datos provenientes de neuroseñal EEG, originada desde el dispositivo Emotiv Epor u otros dispositivo EEG?

Problema Especifico 2: ¿Cuál es el tratamiento que se le debe dar al procesamiento de la señal?

Problema Especifico 3: ¿Qué técnicas, ¿cómo y cuándo se debe aplicar aprendizaje automático al dato originado del procesamiento de la señal?

Problema Especifico 4: ¿Cómo garantizar que la técnica empleada de aprendizaje automático detecte, clasifique e identifique de manera valida y veraz, estados mentales relacionados con la meditación, mindfulness o demás asociados? (Bajo un desempeño estadístico significativo, por encima del nivel de azar)

Problema Especifico 5: ¿Cómo realizar la validación adecuada originada con datos de prueba que se realicen sobre la interfaz?

1.2.3. Delimitación de la investigación

Esta investigación fue llevada a cabo en la Universidad de Caldas y el Centro de Bioinformática y Biología Computacional de Colombia, en marco del proyecto de regalías “Fortalecimiento de ciencia, tecnología e innovación en biotecnología para el departamento de Caldas apoyado por Infraestructura computacional avanzada y trabajo colaborativo” en la ciudad de Manizales, Caldas, Colombia, y fue realizada durante los años 2015 al 2018.

Inicialmente, se propone un Framework preliminar para acelerar el aprendizaje y la efectividad de la meditación mindfulness. Posteriormente, especificamos esta idea con un prototipo basado en un software para análisis inteligente de los datos de la actividad cerebral, registrada durante un periodo de tiempo determinado relacionado con el ejercicio de la atención plena o consciente.

1.3. Justificación

Principalmente este proyecto se origina de la iniciativa del Gobierno Nacional a través del Ministerio de las Telecomunicaciones MinTIC y el Departamento Administrativo de Ciencia y Tecnología - Colciencias, mediante alianzas institucionales con diversas organizaciones de la academia y la industria quienes han liderado la creación del Centro de Bioinformática y Biología Computacional de Colombia BIOS, como parte de la estrategia para descentralizar el desarrollo de la innovación, ciencia y tecnología en el país e impulsar el potencial investigativo a lo largo del territorio nacional en las áreas relacionadas con la computación y las ciencias de la vida. Esta investigación se desarrolla en el marco del proyecto de regalías “Fortalecimiento de ciencia, tecnología e innovación en biotecnología para el departamento de Caldas apoyado por Infraestructura computacional avanzada y trabajo colaborativo” bajo la gestión de la Gobernación de Caldas. La Universidad de Caldas como socio de BIOS auspicia este proyecto a través del programa de Maestría Ingeniería Computacional de la Facultad de Ingeniería, el programa de postgrado, se encuentra soportado en el grupo de investigación en Tecnologías de la Información y Redes GITIR.

El presente trabajo está orientado a proyectar un prototipo computacional basado en un sistema de información que parte de un modelo de análisis de datos para el aprendizaje de la meditación en seres humanos, utilizando artefactos de la inteligencia artificial aplicados a datos originados en la medición del potencial eléctrico sobre el cráneo. Conjuntamente se establece un enfoque de experimentación preliminar a casos del estudio de la meditación mediante procesamiento inteligente de datos cerebrales a nivel de electroencefalografía, utilizando interfaces cerebro computador BCI.

Entre los beneficios que pueden derivar de esta investigación se encuentran: La creación de un prototipo computacional basado en el análisis de datos cerebrales orientados a la meditación basado en la clasificación de mente divagante, el cual, desde el enfoque de la ingeniería biomédica, podría en una etapa avanzada, presentarse como un mecanismo de atención primaria y asistida para el aprendizaje del mindfulness, vista como una terapia en el manejo de algunos trastornos mentales. Presentar un nuevo enfoque al estudio de la meditación desde las interfaces cerebro computador mediante artefactos propios de la inteligencia artificial. Una nueva aplicación a la inteligencia artificial desde el punto de vista de uso de los datos cerebrales con un enfoque técnico

en el estudio del mindfulness además de elaborar una aproximación científica a la mente divagante visto desde la analítica de datos.

Este proyecto busca el fortalecimiento de la ciencia, tecnología e innovación en biotecnología para el departamento de Caldas apoyado por Infraestructura computacional avanzada y trabajo colaborativo y así establecer alianzas interinstitucionales entre la universidad y el estado. Además de apoyar las líneas de investigación en Ingeniería del Software y Sistemas de Información, Inteligencia Computacional, Modelos bio-computacionales y Bioinformática dentro del grupo GITIR de la Universidad Caldas. Así como aportar al desarrollo de las líneas de investigación en Bioingeniería e Inteligencia Artificial del Centro de Bioinformática y Biología Computacional de Colombia BIOS.

Según estudios financieros del Banco de Silicon Valley la inteligencia artificial y las ciencias de la vida apuntan a liderar el mercado de los nuevos negocios en tecnología e innovación alrededor del mundo (Silicon Valley Bank, 2018) generado una economía basada en la aplicación de técnicas de cómputo avanzado a diversos aspectos de la vida diaria como el transporte, el gobierno, la seguridad, el mercado, la economía y la salud.

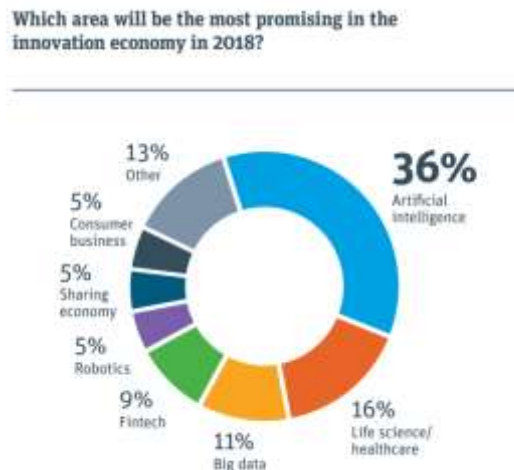


Ilustración 2 Grafico con las áreas más prominentes en la economía de la innovación en el 2018 (*Silicon Valley Bank, 2018*)

Las implicaciones prácticas de esta investigación a nivel de ingeniería están orientadas al uso de aprendizaje automático en el análisis de actividad cognitiva, en el contexto del modelo del proceso del desarrollo de Machine Learning, el cual difiere significativamente del proceso de desarrollo de software tradicional partiendo de la definición de problemas y objetivos, pasando por la recolección y preparación de datos, aprendizaje del modelo, despliegue e integración del modelo y por ultimo administración del mismo. Surge entonces la necesidad de la integración de técnicas propias del procesamiento de señales y bases de la neurociencia computacional en la preparación de datos. Entre las aplicaciones prácticas de este proyecto se encuentra el uso de Interfaces Cerebro Computador, sencillas y portables, dotadas de inteligencia artificial, integradas en herramientas informáticas de medición y procesamiento, todo lo anterior sirven como bases para ofrecer un enfoque preliminar al estudio de la meditación, con utilidad biomédica basada en ingeniería computacional.

El uso de aparatos EEG contextuales, portátiles de baja resolución, en la aplicación de interfaces cerebro computador, mediante procesamiento de inteligente de datos, para aplicaciones del mundo real, es cada vez más factible. Aplicaciones como pilotear un drone con comandos de la mente; desarrollar sistemas de comunicación cerebral no verbal, basado en las ondas cerebrales; monitorear el cerebro de un pasajero al conducir un lujoso automóvil jaguar y medir sus niveles de stress y emoción; hasta permitir que niños con parálisis cerebral creen piezas de música clásica, son tan solo algunos de los proyectos que junto con este trabajo proyectan en uso de computación en función de extender la mente a una gran cantidad de programas informáticos.

El Valor Teórico de este trabajo se fundamenta en el hecho en que a través de la inteligencia Artificial particularmente en el campo del Machine Learning, se valide la aplicación de técnicas de aprendizaje supervisado para la clasificación de lecturas de EEG asociadas con las frecuencias espectrales del Default Mode Network y la meditación. Además del uso de técnicas no supervisadas, como regresión mediante redes neuronales para detectar patrones relacionados estados de mente divagante y meditación, de la misma manera se abordan otras técnicas como el Análisis de Componentes Principales, entre otras más, útiles para ponderar regiones del cráneo con mayor influencia para la detección de estados mentales relacionados con Default Mode Network y meditación. Desde el procesamiento de señales la exploración y uso de técnicas aplicadas a las neuroseñales, para elaborar reducción o cancelación de artefactos, análisis espectral de señales estacionarias y no estacionarias. Llevado al campo de la investigación de la mente, se vislumbra el cerebro, como un mecanismo generador de una gran cantidad de datos para el análisis computacional. Todo esto conjugado en explorar y aplicar técnicas de la inteligencia artificial que puedan brindar información útil de los análisis realizados con un dispositivo científico EEG contextual. Para enmarcar esta idea en una vista desde el desarrollo de software surge la implementación de interfaces graficas de usuario para la validación y visualización de los resultados del procesamiento de datos cerebrales, orientados al ámbito de la meditación.

La utilidad metodológica radica desde el paradigma del ciclo desarrollo del aprendizaje automático, comenzando por la recolección de datos, el preprocesamiento y la limpieza, sumado a la capa de procesamiento inteligente de datos, pasando por la etapa de prototipado y finalizando con la integración y aplicación del modelo. Desde el enfoque mismo de la inteligencia artificial se propone definir una arquitectura basada en técnicas de aprendizaje automático que satisfagan en términos de rendimiento y precisión el análisis de datos cerebrales, así como dar un enfoque de las técnicas de clasificación y aprendizaje que puedan ser aprovechadas para el análisis de la mente humana en estado de meditación y divagación mental.

Este proyecto plantea el diseño de un modelo e implementación de un prototipo computacional orientado a estudiar la respuesta del cerebro frente a la caracterización a nivel de datos, de la actividad de tener pensamientos divagantes expresada, en el DMN, comparada con la actividad cognitiva al inducir estados de meditación.

1.4. Objetivos:

1.4.1. Objetivo general

Diseñar un modelo e implementar un prototipo computacional, para la detección de estado de mente divagante, que contribuya en el aprendizaje de la meditación.

1.4.2. Objetivos específicos

Establecer los datos provenientes de análisis neuronales con el fin de proyectar experimentos para la detección del Default Mode Network (DMN).

Evaluar las técnicas de procesamiento de neuroseñales EGG para la detección de DMN a través de dispositivos BCI.

Determinar y aplicar técnicas de análisis de datos a partir de técnicas de clasificación y aprendizaje automático que aproximen la caracterización de mente divagante.

Validar el prototipo del sistema mediante pruebas que se llevaran a cabo sobre la interfaz.

1.5. Estructura del documento

La estructura del presente documento después de este capítulo es la siguiente:

Capítulo 1 Introducción: En esta sección se plantea de manera cualitativa el problema de investigación enmarcado dentro de diversas áreas temáticas que van desde la neurociencia, las interfaces cerebro computador, la inteligencia artificial y la ingeniería.

Capítulo 2 Marco Teórico y estado del arte: Se muestra una aproximación teórica a la estructura del cerebro, procesamiento de señales EEG y la IA. Además de registrar el estado del arte de los fenómenos de estudio como la meditación y la mente divagante.

Capítulo 3 Descripción detallada del proceso: Se ofrece un panorama detallado de las técnicas de captura y procesamiento de señales EEG, las técnicas de ML aplicadas al análisis EEG, así como a la evaluación del desempeño.

Capítulo 4 Análisis de resultados: Basado en el análisis estadístico se evalúan técnicas paramétricas y no paramétricas para la evaluación del desempeño de los algoritmos y las técnicas de procesamiento empleadas en clasificación de mente divagante.

Capítulo 5 Conclusiones y Recomendaciones: Análisis detallado de cada uno de los objetivos en función de los resultados obtenidos y la perspectiva futura en el análisis de datos EEG para detección de mente divagante como base de un framework para meditación basado en IA.

2. CAPITULO 2. REVISIÓN BIBLIOGRÁFICA

2.1. Marco teórico

2.1.1. Procesamiento de Señales Bioeléctricas y Electroencefalografía:

2.1.1.1. *Señales bioeléctricas*

La función del cuerpo humano está comúnmente asociada con la generación de señales eléctricas, químicas y auditivas. Estas señales contienen información que puede ser “decodificada” o extraída de tal manera que se obtengan interpretaciones significativas. Estas señales reflejan a los sistemas biológicos subyacentes, y su decodificación es de gran aporte en el tratamiento de diversas patologías. En muchas ocasiones el proceso de interpretación puede realizarse visualmente en pantallas de computador, o en papel. Sin embargo, también existen señales complejas, que requieren procesamiento biomédico, el cual se ha vuelto preponderante en el hallazgo de patrones complejos o escondidos.

El procesamiento de señales biológicas es un campo interdisciplinar que requiere conocimientos en fisiología, con el fin de evitar distorsionar o remover información de importancia. Además de anatomía, álgebra lineal, cálculo, estadística, diseño de circuitos, teoría de señales, programación de computadores y de manera más reciente inteligencia artificial y Aprendizaje Automático.

El procesamiento de bioseñales se ha visto como un eslabón para llegar a sistemas de análisis y diagnóstico completamente automatizados. Inclusive antes del advenimiento de los computadores el objetivo primordial era la automatización. No obstante, este objetivo ha sido ampliado a lo largo de los años debido a la complejidad y esto implica que la responsabilidad de los diagnósticos recaía sobre un médico quien era el encargado de desarrollar los sistemas en el pasado, y tan solo en casos muy puntuales estaba garantizado. El objetivo en la actualidad es poder desarrollar sistemas computacionales orientados a ayudar al médico o inclusive completamente automatizados para tomar decisiones basadas en el criterio correcto. Los sistemas de procesamiento de señales son de gran importancia es este aspecto.

En la investigación biomédica se ha utilizado el análisis de un solo tipo particular de señal al tiempo (análisis de señal unimodal). Que en parte centra el trabajo actual con las ondas cerebrales, más aún el análisis de señales multimodales y cómo interactúan entre si es cada vez más útil para conocer cómo interactúan distintos subsistemas fisiológicos el uno con el otro. Por ejemplo, en un sistema cardiovascular, como interactúa la presión de la sangre en función del ritmo del corazón. Explorando la información mutua entre varios sistemas se pueden llevar a mejores diagnósticos. Se pretende que a medida que la capacidad computacional y la eficiencia de los algoritmos aumenten no será una limitante en términos de la complejidad algorítmica del análisis multimodal.

Objetivo y contexto del procesamiento de señales biomédicas

Los objetivos de las señales biomédicas son diversos, a continuación, se muestran los más importantes aplicados al contexto del procesamiento de señales biomédicas.

En un contexto histórico la mayoría de las señales ha sido analizada visualmente asegurando procesos manuales que se aseguran de manera estandarizada. Sin embargo, existe poca concordancia entre los datos manuales generando desviaciones en los diagnósticos. Siendo este uno de los objetivos del procesamiento de señales manuales en reducir la subjetividad de las medidas.

La introducción de métodos computacionales ha cuantificado diferentes características de las señales con el fin de mejorar la precisión de las medidas, así como su reproducibilidad.

La **extracción de características** es uno de los métodos de procesamiento de bioseñales que se utilizan para reducir la subjetividad de las medidas. Los métodos de extracción de características permiten imitar ciertas verificaciones manuales, pero de la misma manera están hechos para extraer patrones que no se encuentran fácilmente detectables de manera visual. Por ejemplo, algunas señales provenientes del corazón no son fácilmente detectables visualmente, pero existen técnicas de procesamiento de señales adaptadas para cuantificar información de carácter clínico de importancia. Es deseable extraer características que tengan significado intuitivo para quien la revisa ya sea bien en el ámbito físico, científico, médico, o inclusive computacional. No necesariamente estas características deben producir el mejor rendimiento en términos clínicos.

En muchas situaciones la señal puede verse sometida a múltiples tipos de ruidos e interferencias. En algunas ocasiones puede estar asociado a procesos fisiológicos del cuerpo humano como la actividad ocular, o también a ruido externo o baja calidad de los electrodos incluido la sujeción al cuero cabelludo. La **reducción de ruido** representa un objetivo crucial en el procesamiento de señales biomédicas. Por lo cual un adecuado procesamiento de señales debe ser aplicado con el fin de separar el proceso mental y/o fisiológico de los demás procesos que interfieren. Esto aplica de manera evidente en ciertos procesos transitorios de baja amplitud como los **potenciales evocados** que son parte de las señales cerebrales y potenciales tardíos en las señales cardíacas.

El **modelamiento de señales** matemático y la **simulación** constituyen otro importante objetivo del procesamiento biomédico de señales con el fin de entender mejor los procesos fisiológicos. Mediante modelos de ecuaciones es posible simular las señales de registros a nivel celular o a nivel del cuerpo, mostrando las relaciones entre los parámetros del modelo y la señal observada. Por ejemplo, un modelo del cerebro para localizar actividad cerebral o un modelo del tórax para las señales cardíacas. El modelamiento de señales también es importante para el “procesamiento de señales basados en modelos” donde el algoritmo desarrollado está en función de una optimización de los criterios de rendimiento. En diferencia el *procesamiento basado en modelos* se centra en optimizar el criterio de rendimiento basado en una señal que se toma como referencia. El otro está orientado a describir sistemáticamente un fenómeno en términos de señales. Este último enfoque no siempre lleva al nivel óptimo de rendimiento; por lo que enfoques heurísticos pueden arrojar mejores resultados. En la industria es conocida la implantación de técnicas ad hoc que ofrezcan un rendimiento satisfactorio.

La complejidad del modelo de la señal se adapta a cada problema en particular en la gran mayoría de procesamientos no es necesario desarrollar un modelo multinivel que tenga en cuenta mecanismos celulares, propagación en el tejido u otras propiedades biológicas. Se recomienda utilizar el modelo que aborde el “fenómeno” de la manera más específica. Para el caso específico de la meditación se considera útil el uso de técnicas multimodales que aborden el problema desde la resonancia magnética funcional, la magnetoencefalografía, entre otras que combinadas con la electroencefalografía pueden arrojar un resultado más holístico del fenómeno de estudio.

Contexto

Existen tres principales contextos en los cuales los algoritmos de procesamiento biomédico son necesarios: diagnóstico, terapia y monitoreo.

En el referente del **diagnóstico** se busca identificar condiciones médicas a través de la información de la señal que reflejen la función de un órgano como el corazón o el cerebro. Generalmente estos procedimientos son no invasivos y de bajo costo, permitiendo ser adaptados fácilmente en cualquier contexto. Las señales pueden analizarse de manera offline o minutos después de la realización del procedimiento. Los algoritmos para procesamiento biomédico no definen completamente el diagnóstico por computadora, más su alcance comprende un rango de operaciones desde el uso simple de filtros hasta formar una parte más substancial en la toma de decisiones médicas.

Desde el punto de vista de la **terapia** implica el tratamiento de enfermedades y de cómo el algoritmo modifica el comportamiento de cierto proceso fisiológico. Este tipo de algoritmos suelen utilizarse en dispositivos implantados como el marcapasos, debe existir una baja complejidad computacional y además ser eficiente con el uso de la fuente de energía. Algoritmos que involucren alta complejidad computacional no son adaptables a esta categoría.

En el **monitoreo** se busca detectar cambios en las funciones fisiológicas como la cardíaca o la neurológica para predecir la evolución de un paciente. En este caso la señal es procesada durante el monitoreo con el fin de obtener un pronóstico basado en los datos procesados en el pasado para la toma de decisiones. Mientras pasan tan solo unos segundos de muestras futuras procesadas. Lo que contrasta notablemente con el enfoque diagnóstico que requiere previa adquisición de la señal para su análisis. Un enfoque no causal puede ser evidenciado en el diagnóstico ya que cuenta con las propiedades del pasado y del futuro. En el monitoreo se deben contar con restricciones en el tiempo máximo de respuesta y tener en cuenta las implicaciones de omitir un evento clínico de importancia o por el contrario notificar al personal médico de falsos positivos.

2.1.1.2. Bases de Señales Bioeléctricas

Básicamente el origen de las bioseñales desde una perspectiva celular surge de los procesos iónicos que aparecen como resultado de la actividad electroquímica de un grupo especial de células que tienen la propiedad de la excitabilidad.

2.1.1.3. Señales Bioeléctricas

Si bien es cierto que las señales bioeléctricas pueden describir actividad del cerebro, del corazón o de los músculos. Este trabajo en particular se centra en la actividad cerebral como objeto de estudio, y particularmente en ciertos estados mentales relacionados como es la mente divagante, expresado a través del Default Mode Network y la meditación. La técnica utilizada para su captura es la electroencefalografía.

El **electroencefalograma** (EEG) refleja la actividad eléctrica en el cerebro registrada mediante la ubicación de varios electrodos en el cuero cabelludo. Ver ilustración número 3. El EEG es usado en la evaluación de diagnóstica de varios desórdenes en el cerebro, como por ejemplo identificar tipo y ubicación de los ataques epilépticos, estudiar trastornos del sueño o como el caso de este proyecto el estudio a nivel bio eléctrico de la mente divagante. De manera similar se pueden aplicar mediciones directas a la superficie descubierta del cerebro durante cirugías mediante electrocorticograma (ECoG).

Los **potenciales evocados** son una forma de actividad cerebral la cual es evocada normalmente por un estímulo sensorial como un origen acústico o visual. Su uso incluye diagnósticos relacionados con estudios visuales y el tronco encefálico. Un potencial evocado o EP de sus siglas en inglés, consiste en una señal transitoria cuyas ondas tienen una amplitud tan pequeña en la lectura subyacente del

EEG que son típicamente invisibles al ojo humano (Ver ilustración numero 4). Los potenciales evocados son registrados con una configuración de electrodos similar a la del EEG.




Ilustración 3 Ejemplo de Señal Bio eléctrica de Encefalograma de la superficie de la cabeza, esta señal contiene actividad alfa, obtenido de un sujeto en condiciones estables (Sörnmo & Laguna, 2005).




Ilustración 4 Ejemplo de señal bio eléctrica resultante de la estimulación. Un potencial evocado EP, resultante de una estimulación auditiva. (Respuesta del tronco encefálico). La señal mostrada es el resultado del promedio de varias respuestas, con el fin de reducir los altos niveles de ruido de la señal origina (reducción de ruido) (Sörnmo & Laguna, 2005)

Existen también otro tipo de señales bio eléctricas, que no comprende el objeto de estudio de este trabajo como señales de electrocardiograma (ECG) que pertenece al corazón, la electromiografía (EMG) que está asociada el registro muscular y óseo, el electroneurograma (ENG) para medir la respuesta de dos nervios mediante electrodos tipo aguja, el electrooculograma (EOG) obtiene los registros del potencial corneo retinal, equivalente a medir le desplazamiento horizontal-vertical de los ojos, el electrogastrograma (EGG) utilizado para obtener actividad eléctrica de los músculos estomacales y su contracción.

2.1.1.4. Análisis y adquisición de señales bioeléctricas.

La adquisición de señales bioeléctricas se puede realizar de manera relativamente sencilla y utilizando dispositivos de bajo costo, que de manera apropiada amplían y digitalizan la señal. Como resultado muchos procedimientos basados en señales bio eléctricas son realizados alrededor del mundo, tanto en clínicas, como en centros de investigación y más recientemente con la inclusión de hardware abierto, con dispositivos de 2 a 16 canales, desde cualquier lugar del mundo. Debido a la inclusión de las tecnologías de la información en la ingeniería biomédica de manera más latente durante las últimas décadas, los sistemas asistidos por computadora han demostrado ser eficientes y efectivos en términos de costos para el análisis de señales. Considerando tanto las ventajas a nivel de hardware como procesamiento gráfico con GPU y TPU. Además de los avances a nivel de software y de algoritmos mediante la aplicación de inteligencia artificial (Ilustración 5).

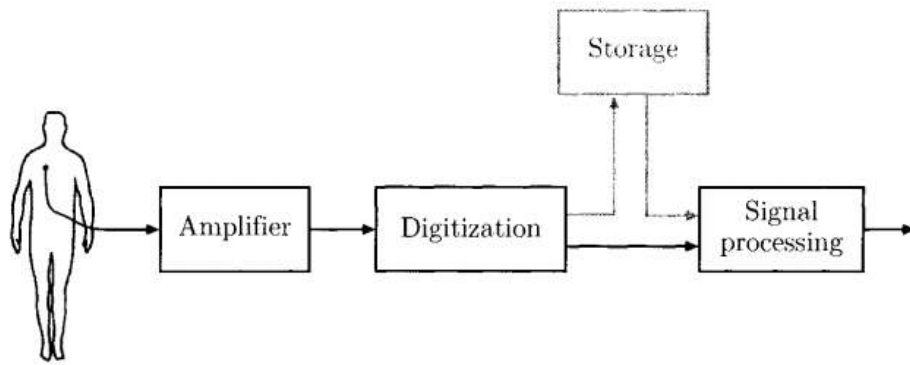


Ilustración 5 Diagrama de bloques que describe los pasos principales del análisis de señales biomédicas. La señal puede ser procesada de manera inmediata (on-line) o puede ser almacenada para su posterior análisis. (Sörnmo & Laguna, 2005)

Con el advenimiento de las nuevas tecnológicas, el análisis no necesariamente debe realizarse de manera local, lo que implica que la señal puede adquirirse en un determinado lugar y ser procesada en un servidor o en la nube. Lo que brinda la posibilidad de utilizar la capacidad de análisis que conlleve al uso de la capacidad computacional necesaria.

2.1.1.5. Evaluación del rendimiento

La evaluación del rendimiento es un aspecto de suma importancia y una parte desafiantes del procesamiento de señales biomédicas antes de que cualquier algoritmo puede ser implementado en un contexto clínico. A diferencia de muchas aplicaciones de ingeniería donde el estímulo fuente de la señal es conocido a priori. El mensaje “enviado” por una fuente bioeléctrica es desconocido y debe ser desenmascarado mediante algún tipo de procedimiento manual de manera que se pueda obtener la mejor evaluación del rendimiento posible. Por ejemplo, para los latidos del corazón es un asunto relativamente sencillo contar el número de latidos por minuto donde el rendimiento vendría dado al comprar el conteo manual con el registro obtenido del algoritmo. La evaluación del rendimiento se torna más complicada cuando el objetivo es desarrollar un algoritmo que procese un conjunto de parámetros que discrimine con precisión señales tomadas de sujetos sanos a aquellos que sufren de una enfermedad en particular. En dichos casos no es posible realizar una apreciación de la salida del algoritmo, ya que la señal observada no es valorada como “verdadera”. En su lugar el rendimiento es dado por la habilidad de discriminar correctamente entre dos grupos de sujetos sanos y enfermos. Las medidas más comunes para describir estas discriminaciones son la especificidad, sensibilidad, valor predictivo positivo y valor predictivo negativo. Cuyas definiciones

se encuentran en la siguiente tabla:

Medida de Rendimiento	Definición	Interpretación
Sensitividad	$\frac{N_{VP}}{N_{VP} + N_{FN}}$	La probabilidad de un resultado positivo (Por ejemplo sujetos que padecen de una enfermedad)
Especificidad	$\frac{N_{VN}}{N_{FP} + N_{VN}}$	La probabilidad de un resultado negativo (Por ejemplo sujetos sanos que NO padecen de una enfermedad)
Valor predictivo positivo	$\frac{N_{VP}}{N_{VP} + N_{FP}}$	Probabilidad de que se presente una enfermedad cuando el resultado es positivo.
Valor predictivo negativo	$\frac{N_{VN}}{N_{FN} + N_{VN}}$	Probabilidad de que un sujeto se encuentre saludable cuando el resultado es negativo

Tabla 1 Medidas de evaluación de rendimiento de un algoritmo de procesamiento de una señal bioeléctrica. Para el caso de estudio de un conjunto de sujetos con presencia o no de una enfermedad.

La evaluación del rendimiento cobra vital importancia, en la medida de que los métodos analíticos propuestos cumplan satisfactoriamente con el rendimiento esperado al ser sometidos a valoración de manera sistemática.

2.1.1.6. Bases de Datos de señales bio eléctricas

La disponibilidad de bases de datos de señales es de vital importancia tanto para el desarrollo como para la evaluación de los algoritmos de procesamiento de señales. Desde el punto de vista clínico dada la gran variedad de patrones de onda existentes para cada sujeto, se requiere la evaluación del algoritmo en una base de datos de tamaño considerable de manera que pueda ser determinada como válida. Desde el punto de vista de la analítica de datos, con el propósito de realizar validación de los algoritmos y las técnicas de análisis empleadas el volumen de datos puede llegar a ser prescindible en términos de empleabilidad de los algoritmos, mas no en términos de rendimiento y validación. En el ámbito del desarrollo del algoritmo es necesario considerar un segmento de la base de datos para la implementación, mientras que otra parte para la validación y pruebas, de tal manera que se descarte que no se realizó aprendizaje durante la evaluación de los datos.

Una base de datos comprende un conjunto de señales que fueron obtenidas bajo los mismos protocolos de captura de un grupo de sujetos sanos y pacientes escogidos adecuadamente. En ocasiones estas bases de datos contienen señales de más de un tipo por ejemplo EEGs, ECGs, EOGs. Las cuales corresponden a capturas realizadas de manera concurrente.

Las anotaciones constituyen otra información importante de las bases de datos en la cual se definen los instantes de tiempo para los cuales ocurren ciertos eventos en la señal. Como son la presencia de las pulsaciones del corazón o convulsiones epilépticas. Las anotaciones también pueden realizarse para información no fisiológica como la presencia de episodios de ruido o deficiencias técnicas como electrodos sin la fijación adecuada. (Ilustración 6). Las anotaciones están determinadas por uno o un grupo de médicos quienes de manera detallada escrudiñan la señal respecto a las propiedades que deben ser anotadas. Alguna otra información de importancia de la señal corresponde al género, raza, altura, peso, medicación, y otros datos que puedan ser de utilidad en la evaluación del rendimiento.




Ilustración 6 Ejemplo de una anotación manual de un ECG de 2 canales a un paciente con isquemia al miocardio. Las barras verticales muestran el número de ocurrencia de los latidos del corazón y las etiquetas N y V indican cuando el latido es normal o cuando tiene origen ventricular. Las 3 barras más largas indican el comienzo de un nuevo ritmo (VT: Taquicardia ventricular, N: Ritmo Seno, y AST1-300 máxima depresión ST de 300 mV. La señal fue tomada de la base de datos europea ST-T (TADDEI et al., 1992)

En la actualidad existen recursos en línea como kaggle y reciente literatura científica con meditación como objeto de estudio, los cuales contienen información de registros EEG para este caso de estudio específico (Grégoire Cattan et al., 2018; <https://physionet.org/>, n.d.; kaggle, 2019; Kaur & Singh, 2015; Lin & Li, 2017). De la misma manera muchos estudios a nivel del corazón, en los cuales se han logrado recapitular información de importancia en el estudio médico de fenómenos coronarios como: La base de datos europea ST-T (TADDEI et al., 1992) cuyo propósito es investigar la ocurrencia de suministro de sangre insuficiente a los músculos del corazón, o la base de datos AHA en la evaluación de detectores de arritmia ventricular (Moody et al., 2001; PhysioNet, n.d.).

Las bases de datos multimodales son bases de datos que incluyen señales de distintos tipos y reflejan la actividad fisiológica en distintos niveles de manera concurrente como actividad cerebral, muscular, respiratoria, presión en la sangre, entre otros, en la siguiente ilustración se puede observar un fragmento de una señal multimodal. Ilustración 7.




Ilustración 7 Señales registradas de manera concurrente de una base de datos multimodal , de arriba hacia abajo: ECG, presión de la sangre, EEG, respiración nasal, EOG, EMG. Este tipo de registros es usado por ejemplo en el estudio de desórdenes del sueño (Ichimaru & Moody, 1999)

Dada la facilidad para acceder y compartir información mediante la web, el acceso a recursos de base de datos con información fisiológica es relativamente sencillo; si bien es cierto que esto facilita el diseño e implementación de algoritmo para el procesamiento de señales debido a que evita la compleja e intensa labor de la recolección de los datos. Se debe tener en cuenta riesgos como que los protocolos de recolección y pre procesamiento satisfagan el objetivo del análisis de los datos de la investigación, de allí la importancia de desarrollar un protocolo de captura de datos para la adquisición de datos propios. De la misma manera es necesaria una curación adecuada bajo un contexto médico y con enlace consistente a la base desde la ingeniería.

Para este propósito existen fuentes como bases de datos y repositorios con información de EEG, las cuales han experimentado recientemente un aumento considerable en cuanto su volumen y disponibilidad. Y que han comenzado a acrecentarse mediante diversos repositorios públicamente liberados, provenientes de investigaciones científicas relacionadas con diversas aplicaciones de Aprendizaje Automático y otras disciplinas a la neurociencia. A continuación, se citan algunas de las

fuentes consultadas durante la fase de investigación exploratoria que gozan de mayor relevancia para el contexto de este proyecto:

- Centro Swartz para la Neurociencia Computacional: Un centro del instituto para la Computación Neuronal de la Universidad de California San Diego (Kothe, 2012). Conocidos dentro de la comunidad de neurociencia como los creadores de una de las más célebres herramientas para análisis de datos EEG, como es EEGLAB. Disponen de un repositorio actualizado al año 2020 con diversidad de datos disponibles para descarga pública y gratuita desde su sitio web https://scn.ucsd.edu/~arno/fam2data/publicly_available_EEG_data.html el cual incluye set de datos para mente divagante (Grandchamp et al., 2014)
- El sitio www.kaggle.com (Kaggle, 2021) comprende un conjunto de recursos para el uso aprendizaje automático entre los que se encuentran bases de datos para análisis EEG <https://www.kaggle.com/datasets?search=eeg> relacionado con el presente proyecto de investigación, como datos de la comunidad para meditación <https://www.kaggle.com/abyssjumper/meditation-eegdata/kernels>, (kaggle, 2019) datos más estructurados como los provenientes de investigaciones formales como los de (Aci et al., 2019) En <https://www.kaggle.com/inancigdem/eeg-data-for-mental-attention-state-detection>. Además de notebooks que detallan metodológicamente el proceso de análisis de datos EEG <https://www.kaggle.com/ruslank/eeg-data-analysis> y con esto la posibilidad de filtrar los datasets disponibles para EEG en <https://www.kaggle.com/datasets?search=eeg>
- Repositorios públicos de GitHub como <https://github.com/meagmohit/EEG-Datasets> que dispone de un completo compendio de recursos web para la obtención de datos EEG bajo distintos protocolos y condiciones de captura.
- OpenNeuro (Stanford Center for Reproducible Neuroscience, 2021) es una base de datos de neuroinformática de ciencia abierta que almacena conjuntos de datos de estudios de investigación de imágenes del cerebro humano. Creado por El Centro de Stanford para la Neurociencia Reproducible en 2015, con el objetivo de aprovechar la computación de rendimiento para hacer que la investigación en neurociencia sea más confiable. Comprende 494 set de datos públicos. Se destaca de este recurso la disponibilidad de sets de datos de meditación como los obtenidos de (Brandmeyer & Delorme, 2018)
- Repositorios de Datos De Machine Learning de Universidad de California Irvine, el cual mantiene 592 conjuntos de datos como un servicio para la comunidad de aprendizaje automático.
- OSF Open Science Framework <https://osf.io/> del (Center for Open Science, 2021) es una herramienta de gestión de proyectos de código abierto y gratuita para garantizar la reproducibilidad de la ciencia a la vez que apoya a los investigadores durante todo el ciclo de vida del proyecto. Dentro de este recurso se resalta la disposición de data sets como: (Dong et al., 2021; Groot et al., 2021; Rodriguez-Larios & Alaerts, 2021)
- DataSet search de Google <https://datasetsearch.research.google.com/> la herramienta de Búsqueda de Datasets de Google research es un buscador de conjuntos y de datos de datos de proyectos científicos.
- PhysioNet es un recurso de investigación de señales fisiológicas complejas www.physionet.org (Moody et al., 2001) PhysioNet, el apodo del recurso de investigación para señales fisiológicas complejas se estableció en 1999 bajo los auspicios de los Institutos Nacionales de Salud (NIH),

como se describe más adelante. Las misiones originales y en curso de PhysioNet Resource eran conducir y catalizar la investigación y la educación biomédica, en parte ofreciendo acceso gratuito a grandes colecciones de datos fisiológicos y clínicos y software de código abierto relacionado.

- La misión de Papers with Code <https://paperswithcode.com/datasets> es crear un recurso abierto y gratuito con documentos, código, conjuntos de datos, métodos y tablas de evaluación de Machine Learning. cuenta con alrededor de 5122 set de datos de Machine Learning dentro de los que se destacan (Y.-T. Chen et al., 2020a) para mente divagante.

Un concepto destacado dentro del procesamiento de señales comprende la simulación, se utiliza para describir cuantitativamente comportamientos fisiológicos mediante ecuaciones matemáticas replicando las señales que son originadas por el cuerpo humano. De manera que se puedan estudiar condiciones que no pueden replicarse experimentalmente. A su vez que las propiedades de la señal simulada pueden ser controladas por un conjunto de parámetros. Siendo la simulación un aporte importante al desarrollo de algoritmos.

2.1.1.7. *Una aproximación al electroencefalograma*

El cerebro humano comprende uno de los órganos más complejos del cuerpo humano. Abarca un amplio espectro de funcionalidades exploradas tanto a bajo nivel en sus propiedades químicas y moleculares, así como aspectos de alto nivel que implican memoria y aprendizaje.

Hans Berger descubrió la generación de “ondas cerebrales” eléctricas mediante el registro llevado a cabo por electrodos sobre el cráneo. Estas ondas mostraban un comportamiento oscilatorio, variante en el tiempo, el cual altera su forma según sea la ubicación sobre el cráneo. Uno de los descubrimientos más significativos realizados por Berger, a parte de las diferencias entre sujetos enfermos y sanos, fue la diferencia entre las ondas cerebrales en diferentes estados mentales. Por ejemplo, si un sujeto se encuentra en estado de relajación, atención, dormido, etc.

La electroencefalografía se encuentra concebida como un método clínico no invasivo, con el fin de comprender el funcionamiento del cerebro humano y su diagnóstico para varias patologías cerebrales. La interpretación clínica del EEG se ha convertido en una disciplina que busca el hallazgo de conclusiones basados en la frecuencia, amplitud, morfología y distribución espacial de las ondas cerebrales. Hasta ahora sin embargo no se ha encontrado un modelo matemático o biológico que explique de manera integral la diversidad de patrones de EEG. Hasta hace algunos años la interpretación de EEG permanecía casi que de manera exclusiva a la fenomenología clínica (Barlow John, 1993). Sin embargo, en la actualidad se realizan gran variedad de estudios con un alcance mayor al ámbito clínico, gracias a las recientes innovaciones de las interfaces cerebro computador, entre las más conocidas por su diversidad de aplicaciones esta Neuralink (Neuralink, n.d.).

A diferencia del escrutinio visual que se consideraba la única técnica de análisis, gracias a la capacidad computacional en la actualidad se cuentan con muchos métodos para su interpretación, mediante una variedad de métodos de procesamiento de señales digitales diseñados para una variedad de propósitos, de manera más reciente a la inteligencia artificial ha abordado el problema de la automatización en la interpretación de resultados. A nivel de procesamiento de señales por ejemplo mejoras en la cuantificación del SNR (Signal Noise To Ratio) de varias características de la señal y la extracción de nueva información no detectable mediante inspección visual (Sörnmo & Laguna, 2005).

El procesamiento de señales está dividido en dos categorías generales: Métodos desarrollados para actividad cerebral espontánea y el segundo donde los potenciales cerebrales son evocados por varios estímulos visuales o sensitivos (Potenciales Evocados EP). Si bien es cierto que la primera ha servido para mejorar la comprensión del fenómeno EEG, el análisis de potencial evocado es críticamente dependiente de la disponibilidad de las técnicas de procesamiento de señales.

A lo largo de la historia se han desarrollado diversas técnicas para el estudio de imágenes médicas de las funciones cerebrales. La tomografía por emisión de positrones (PET), la tomografía computarizada por emisión simple de fotón (SPET) e imagen por resonancia magnética (MRI), los cuales pueden producir imágenes bi o tri dimensionales con una considerable resolución espacial. Estas modalidades de imágenes son una extensión de la información inferida de la investigación electrofisiológica, como resultado el EEG ha perdido parte de su dominancia en el contexto clínico. Sin embargo, sigue siendo una herramienta poderosa en estudios de trastornos del sueño, epilepsia y demencia. Así como una herramienta fundamental para el monitoreo, ya que la resolución temporal por segundos del EEG permanece insuperado frente a las técnicas de imágenes mencionadas más arriba. Otro aspecto de importancia es el costo asociado a la instrumentación y manejo de los equipos que es notablemente menor al de los equipos de neuro imagen. La demanda técnica de un equipamiento para EEG es relativamente modesta, para un registro básico basta con disponer de un arreglo de electrodos, un amplificador de señal y un computador. Este último ha cobrado en la actualidad un papel más preponderante en términos del almacenamiento, análisis y representación gráfica de la señal.

El magnetoencefalograma (MEG) es otra técnica no invasiva que cuantifica la intensidad del campo magnético de la actividad neuronal en masa usando un sensor electromagnético de alta sensibilidad. La principal ventaja de este método es que es menos propenso a distorsiones a través del cráneo que el potencial eléctrico.

Seguidamente de los bases bioeléctricas para la adquisición de datos EEG, explicando anteriormente, se da paso a una breve introducción a los mecanismos subyacentes en el cuerpo humano para la generación de ondas cerebrales y la caracterización de las ondas, como se muestra a continuación:

2.1.1.8. *El sistema nervioso*

El sistema nervioso recolecta, comunica y procesa información de varias partes del cuerpo y asume que tanto funciones internas como externas son administradas de manera rápida y exacta. El sistema nervioso se divide en sistema nervioso central SNC y Sistema Nervioso Periférico SNP, conectando al cerebro con la espina dorsal con los organismos del cuerpo y los sistemas sensitivos. Ambos sistemas están estrechamente ligados ya que la entrada del SNP es procesado por el SNC y enviados nuevamente a los órganos sensitivos del cuerpo por el SNP, los nervios que llevan las señales al SNC son llamados *aferentes* o alternativamente *nervios sensitivos*. Y los nervios que transmiten la señal desde el SNC son llamados *eferentes* o *nervios motores*. Ya que estas señales pueden conllevar a contracciones musculares.

Otra división basada en su funcionalidad es en sistema nervioso somático y autónomo, el primero se encarga de ejecutar los comandos conscientes y el segundo los que van más allá de la conciencia, como la actividad cardiaca o la regulación de los músculos de la vejiga. El sistema nervioso autónomo se divide en dos subsistemas que operan el uno contra el otro: El sistema nervioso simpático que es dominante durante la actividad física y parasimpática que opera durante la

relajación. Estos dos sistemas subsisten sobre los mismos órganos con el fin de mantener un control equilibrado. Por ejemplo, durante la actividad física el sistema simpático incrementa la actividad cardíaca mientras que el parasimpático la disminuye. La variabilidad cardíaca es el resultado entre la interacción de estos dos subsistemas. Este tema ha sido objeto de estudio médica en el análisis de enfermedades neurológicas y disfunción del sistema nervioso autónomo.

2.1.1.9. *Las neuronas*

La unidad básica del sistema nervioso es la célula nerviosa. La neurona. La cual comunica la información desde y hasta el cerebro. Las neuronas pueden ser clasificadas de acuerdo con su morfología o funcionalidad. Con base a su función pueden ser sensores, motoras o interneuronas.

De manera arquetípica la neurona comprende una célula del cuerpo, el *soma* de la cual se extienden dos estructuras: las *dendritas* y el *axón*. Ver Ilustración 8.a Las dendritas comprende muchos cientos de brazos, cada brazo recibe la señal de otra neurona. El axón es generalmente una sola rama que transmite la salida de la señal de la neurona, a varias partes del sistema nervioso. La longitud de los axones varía de 1mm hasta 1m que recorre desde la espalda hasta los pies.

La transmisión de información de una neurona a otra se realiza mediante la sinapsis, que comprende el enlace entre el inicio de una neurona y el fin de la que le antecede. La señal iniciada en el soma se propaga a través del axón codificado mediante un pulso corto en forma de onda. Por ejemplo, el potencial de acción. Aunque esta señal sea eléctrica es convertida a través de la neurona presináptica en una señal química (“neurotransmisor”), la cual se difunde a mediante el espacio sináptico, y es reconvertida de manera subsecuente en una señal eléctrica en la neurona post sináptica. Ver Ilustración 8.b

La sumatoria de las señales recibidas en la entrada sináptica son realizadas por la neurona post sináptica. La amplitud de las señales consolidadas depende del número de señales de entrada y de que tan cercanas son estas señales a través del tiempo. La amplitud disminuye a medida que las señales se dispersan en el tiempo. La amplitud de la señal sumada debe exceder cierto umbral de manera que la neurona dispare su potencial de acción.




Ilustración 8 La neurona, dendritas y axones , (a) neurona arquetípica, (b) Tres neuronas intercomunicadas, la neurona presináptica transmite la señal mediante la sinapsis, en donde una neurona post sináptica prosigue con la trasmisión de la señal que proviene de la sinapsis. (Sörnmo & Laguna, 2005)

De la misma manera que las neuronas post sinápticas son susceptibles a estímulos, también lo son a la inhibición debido a estructuras químicas particulares asociadas con ciertas neuronas. Esta salida depende de cómo las señales son sumadas conjuntamente. Las operaciones de entrada/salida representan un cálculo neuronal realizado de manera repetida en billones de neuronas.

A diferencia de la actividad neuronal medida en el cráneo, la actividad propagada a través del axón es manifestada a lo largo de *potenciales de acción*. Todas mediante formas de onda de distintas amplitudes. Este comportamiento viene dado por la propiedad de “encendido y apagado” de las neuronas, dichos estados pueden ser provocados por potenciales de acción de una amplitud fija o no ocurrir del todo. La intensidad de la señal de entrada viene dada por la tasa de activación de los potenciales de acción, por ejemplo, esta propiedad de la señal implica que las neuronas del dolor o de la activación muscular pueden estar asociadas con una tasa alta de activación de las neuronas sensitivas. Este sistema de modulación está diseñado para transmitir información a grandes distancias y ser tolerante a fallos locales.

Las neuronas no trabajan de manera aislada, sino que están conectadas mediante distintos circuitos, llamados “redes neuronales”, por ejemplo, el acto reflejo de la rodilla al ser golpeada ligeramente.

Los conglomerados o las redes de neuronas se extienden a lo largo del córtex cerebral, como se muestra a continuación:

2.1.1.10. El córtex cerebral

El córtex cerebral es la parte más importante del sistema nervioso central. A lo largo del córtex se encuentran las regiones responsables de procesar las funciones visuales, sensaciones, aprendizaje, movimiento voluntario, habla y percepción. La corteza cerebral es la parte más externa del cerebro y tiene un grosor entre 1 y 3mm. El córtex neuronal se encuentra altamente confluido entre valles y rugosidades, con un área total de 2.5 m², con más de 10 billones de neuronas. El córtex se divide en dos hemisferios simétricos, derecho e izquierdo. Separados por la fisura central sagital. Cada hemisferio se encuentra dividido en 4 zonas: Frontal, parietal, temporal y occipital. Ver Ilustración 9.

El movimiento voluntario es controlado en primera medida por el lóbulo frontal, que se encuentra en la parte anterior del surco central llamada Corteza motora. Allí se controlan actividades relacionadas con el control muscular. Habla, ciertas expresiones faciales y el movimiento de los dedos. La información sensorial se encuentra distribuida a lo largo de los lóbulos, la auditiva en el temporal, el córtex visual en la parte posterior de los occipitales, y el córtex somático sensor localizado en la parte posterior del surco central del lóbulo parietal.

Las áreas mencionadas previamente son conocidas como las zonas primarias y son especialidades para un propósito particular. En las cuales se desarrollan muchas de las habilidades mentales del ser humano. El área secundaria de las neuronas analiza por ejemplo con más detalle lo procesado en la corteza visual, como color, tamaño, forma, etc. Las neuronas también proveen otras referencias asociativas que integran la información presente con experiencias y conocimientos previos.




Ilustración 9 El córtex cerebral y sus 4 lóbulos. (Sörnmo & Laguna, 2005)




Ilustración 10 Detalle de los lóbulos cerebrales , visión periférica a color, Curso Modern BCI design capítulo 02 EEG Basics Insituto Swartz (Kothe, 2012)

2.1.1.11. EL EEG la actividad eléctrica medida en el cráneo.

La actividad eléctrica colectiva en el córtex cerebral es usualmente conocida como *ritmo* (*del ingles rhythm*). Esto debido a que las señales medidas exhiben un comportamiento oscilatorio y repetitivo. Esta medición no se realiza a nivel de la neurona cortical simple debido a factores anatómicos como las capas de tejido (fluidos, huesos y piel) los cuales atenúan la señal eléctrica propagada a través del electrodo ³, sin embargo, la suma de todas las neuronas corticales produce un campo eléctrico lo suficientemente “fuerte” para ser medido en el cráneo. El campo eléctrico es generado por las corrientes que fluyen a lo largo de la excitación sináptica de las dendritas, llamados los potenciales post sinápticos excitadores.

La diversidad de ritmos de EEG viene dada por un conjunto de variables, entre otras el estado mental del sujeto. Así como su grado de atención, alerta o de sueño, entre otros. La Ilustración 11 muestra una muestra de EEG observados durante diferentes estados mentales. Los ritmos son generalmente caracterizados por su rango de frecuencia y amplitud relativa.

La **amplitud** de la señal EEG está relacionada con el grado de sincronía con la que interactúan las neuronas corticales. La excitación sincrónica de un grupo de neuronas produce una señal de gran amplitud en el cuero cabelludo porque las señales que se originan en las neuronas individuales se sumarán de manera coherente en el tiempo. La repetición de la excitación sincrónica da como resultado una señal de EEG rítmica, que consta de formas de onda de gran amplitud que se producen a una determinada tasa de repetición. Por otro lado, la excitación asíncrona de las neuronas da como resultado un EEG de aspecto irregular con formas de onda de baja amplitud. En ambos casos,

³ Es posible medir esta actividad intra cerebralmente con procesos invasivos con el uso de micro electrodos.

La excitación puede muy bien implicar un número idéntico de neuronas, pero, dependiendo de la dispersión temporal de la entrada neuronal, resultan diferentes amplitudes del EEG.

La **frecuencia** del rango oscilatorio es soportada de manera parcial por el tálamo. Esta parte del cerebro consiste en neuronas que tienen la capacidad de funciones como las propiedades de un marcapasos. Generando un comportamiento "rítmico" que puede ser originado de manera intrínseca debido a un patrón de activación sostenido o que puede también provenir de la interacción de neuronas corticales en regiones específicas de córtex. En todo caso más que una función de marcapasos, el ritmo surge como un mecanismo de retroalimentación que puede ocurrir en un circuito neuronal(Wood, 1996).

La relación entre ritmos de alta frecuencia/baja amplitud y baja frecuencia/alta amplitud. Viene dada por la presencia de estados mentales de alerta o letargo respectivamente. Esta relación es lógica ya que el córtex es más activo cuando está encargado de procesar información sensorial o en la realización de algún proceso interno. La actividad de las neuronas a nivel cortical es alta, pero de manera relativamente asíncrona. Soportando la teoría de que cada región comprendida por las neuronas está involucrada en diferentes aspectos de una tarea cognitiva. Esto se genera de manera rápida mas no simultanea entre las regiones cercanas, llevando a baja sincronía y por lo tanta baja amplitud del EEG. De manera contraria pasa durante estados de sueño profundo donde las neuronas corticales no se encuentran en involucradas en procesamiento de información y las neuronas son excitadas por fases mediante un ritmo común de entrada. En este caso la sincronía es alta y por ende la amplitud del EEG alta. El significado de las ondas cerebrales ha sido objeto de estudio durante las últimas décadas brindando un panorama diagnostico al estudio funcional de los estados del cerebro, más aun, muchos ritmos cerebrales continúan en estudio y algunos más, sin explicación definitiva.




Ilustración 11 Diferentes magnitudes de electroencefalografía expresados en función del tiempo observado durante varios estados de alerta a dormido: (a) excitado, (b) relajado, (c) aletargado, (d) fase inicial del sueño, (e) profundamente dormido. Siendo este un ejemplo clásico originalmente presentado por el famoso pionero del EEG H.H. Jasper. (Sörnmo & Laguna, 2005)

2.1.1.12. Ondas y ritmos EEG

Las características principales de las ondas cerebrales y ritmos recolectados del cráneo en general contienen amplitudes que varían desde algunos micro voltios a aproximadamente $100 \mu\text{v}$ y en una frecuencia que va del rango de los 0.5 a los 30 -40Hz. Convencionalmente estos ritmos EEG son clasificados en cinco distintas bandas de frecuencia. La interpretación en términos de determinar si una muestra es “normal” o “anormal” depende de variables como la edad y el estado mental del sujeto. Por ejemplo, el EEG de un recién nacido varía drásticamente con el de una persona mayor. Grosso modo se describen a continuación las bandas de frecuencias, sin embargo, esta categorización provee significación en términos clínicos.

Ritmo Delta, < 4Hz: El ritmo delta es encontrado normalmente en sueño profundo y es de gran amplitud. Nos es observado de manera usual en estado de atención o despierto de un adulto en condiciones normales, puede significar un daño cerebral o enfermedad del cerebro.

Ritmo Theta, 4 – 7Hz: El estado theta ocurre en estados de somnolencia, o durante las primeras fases del sueño.

Ritmo Alpha, 8 – 13Hz: Este ritmo es prominente en sujetos bajo condiciones normales, que se encuentran en estados de relajación, despiertos y conscientes. Esta actividad es suprimida al abrir los ojos. La amplitud del ritmo alpha es mayor en las regiones occipitales.

Ritmo Beta, 14 – 30Hz: Es un ritmo rápido de baja amplitud. Asociado con actividad en el córtex, el cual puede ser observado por ejemplo durante ciertas etapas específicas del sueño. El ritmo Beta es observado mayoritariamente en las regiones frontales y centrales del cráneo.

Ritmo Gamma, > 30Hz: El ritmo gamma puede observarse durante etapas de actividad intensa de procesamiento de información en el córtex, usando un electrodo ubicado cerca del área sensorial-motora y conectado a una técnica de captura de alta sensibilidad, el ritmo gamma puede ser observado durante el movimiento de los dedos.

La mayoría de estos ritmos pueden estar presentes en un registro EEG durante varios minutos. Mientras que otros por presencia de algunos segundos, como el ritmo gamma. Cabe resaltar que un ritmo no está presente de manera permanente. Sino que se presente de manera irregular y arrítmica la cual puede prevalecer los largos periodos de tiempo.

2.1.1.13. Categorización de la actividad en EEG

Actividades cerebrales provenientes de actividades como el sueño o de trastornos como la epilepsia, entre otros estados mentales, pueden ser clasificadas en cuatro grupos de acuerdo con su grado de fase no estacionaria. Las categorías fueron definidas con referencia especial a su adaptación al análisis espectral (Gasser & Molinari, 1996).

Actividad sin mayores cambios a nivel temporal: En estado de actividad espontánea (condiciones normales) durante el descanso. Por ejemplo, con los ojos cerrados y abiertos. La hay de varios tipos theta, alpha y beta.

Actividad lentamente variante en el tiempo: Actividad subyacente durante el sueño, estado postictal (referente al estado del cerebro tras un choque epiléptico), o durante episodios convulsivos prolongados.

Actividad Intermitente: Presentada de manera intermitente, con ritmo lento. Relacionado con patrones de sueño. Por ejemplo, actividad con patrones estables durante intervalos de varios segundos.

Actividad Paroxística: Ondas con picos y agudas, ondas complejas con picos, formaciones en pico de 3Hz, comprende ondas de vértice observadas al dormir durante actividad transitoria.

2.1.1.14. Técnicas de registro y captura de datos EEG

La captura del EEG se realiza generalmente bajo el sistema de posicionamiento de electrodos 10/20, este sistema de montaje de electrodos emplea 21 electrodos sujetos a la superficie del cráneo definido para ciertos puntos de referencia anatómica. Los números 10 y 20 son los porcentajes de las distancias relativas entre cada una de las referencias en la superficie del cuero cabelludo. Ver Ilustración 12. Electrodo tanto bipolares como unipolares se utilizan en la captura clínica.

El espaciado de los electrodos dentro del sistema 10/20 es relativamente disperso. La distancia inter-electrodo es de aproximadamente 4.5 cm. En la cabeza de un humano adulto. En caso de que la actividad EEG se desee medir sobre un punto específico se puede aumentar la resolución. El mapeo comprende una técnica de análisis a nivel topográfico para realizar divisiones del cráneo por

regiones. Usar un poco cantidad de electrodos puede conllevar a alienar el dominio espacial y de manera consecuente la actividad eléctrica será representada de manera inexacta. Estudios han demostrado que con el fin de obtener resultados con exactitud se deben usar 64 electrodos o más.

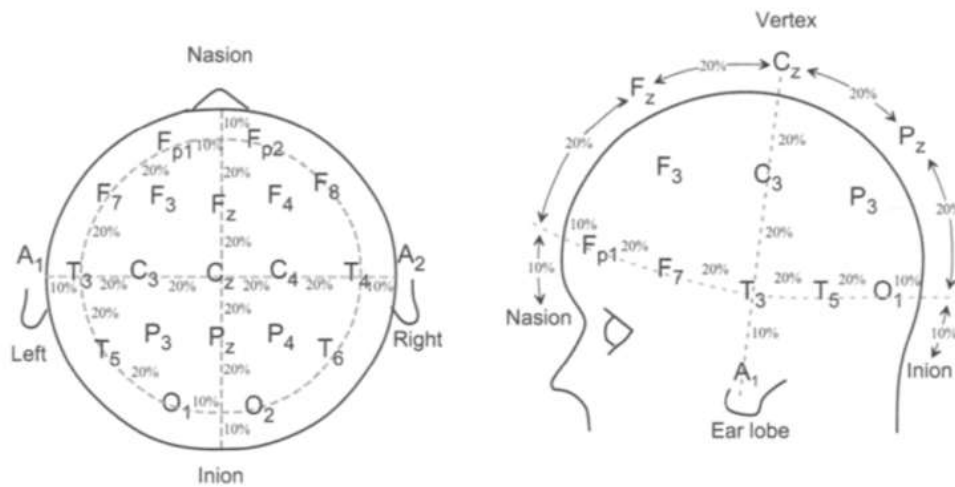


Ilustración 12 Sistema Internacional de posicionamiento de electrodos 10/20 para registro de EEGs clínicos. La referencia anatómica de los puntos de referencia esta definida desde la punta de la nariz (Nasion) y la parte trasera del cráneo (Inion). Las letras F, P, C, T, O y A denotan las iniciales en ingles de las zonas frontal, parietal, temporal, occipital y aurícula respetivamente. Los electrodos pares están en la lado derecho y los impares en el izquierdo y Z que corresponde a 0 en la mitad. (Sörnmo & Laguna, 2005)

La tasa de muestreo para la adquisición de la señal EEG se encuentra alrededor de los 200Hz, cuando se toman rangos de frecuencia de actividades rítmicas (cerebrales) como trastornos de sueño o epilepsia. Para un análisis más detallado de ondas evocadas o transitorias, se requiere una tasa de muestreo mucho mayor, siendo esto un aspecto abarcado en mayor profundidad por los Potenciales Evocados PE.

2.1.2. Interfaces Cerebro Computador BCI

Una interfaz cerebro-computadora (BCI) permite que un sujeto se comunice y controle el mundo externo sin utilizar la salida normal de la ejecución del cerebro a través de nervios y músculos periféricos (Sörnmo & Laguna, 2005). En este caso los mensajes son transportados por actividad EEG espontanea o Potenciales Evocados más que por la contracción muscular propiamente dicha a través del habla o la escritura. Sujetos con problema de habla, desordenes neuromusculares, paralizados parcial o totalmente (Síndrome de parálisis muscular), obtienen grandes beneficios de las BCI, mediante capacidades que les permitan expresarse a sí mismos, mediante a programas de deletreo u operando neuro-prótesis. Si bien las BCI fueron concebidas a principios de los años 70, no es sino hasta las 90's e inicios del siglo XX cuando gracias a los avances en tecnología computacional (Sörnmo & Laguna, 2005) se ha logrado obtener un conocimiento más detallado acerca del conocimiento de las señales EEG.

Los dos pasos fundamentales para poder diseñar y usar BCI son:

- El proceso mental el cual el usuario desea codificar en comandos en la señal EEG.

- La BCI que debe contar con técnicas sofisticadas de procesamiento de señales que traduzcan las características de la señal EEG en comandos para el control de un dispositivo o software informático.

La imaginación o la acción mental de ejecutar una acción como mover una mano o un pie, está asociado con ciertas características a nivel de la señal EEG que se pueden codificar en una serie de comandos (Sörnmo & Laguna, 2005). El proceso mental relacionado se refiere usualmente como *imaginación motora* (Del inglés *motor imagery*), excepto que el motor, es decir la actividad muscular está bloqueada. De tal manera que la manera que la BCI pueda aprender del significado de diferentes características EEG asociadas a la ejecución de un conjunto de acciones realizadas por un sujeto. Para cada una de las acciones, se extraen un conjunto de parámetros descriptivos de la señal EEG y son sometidos como parámetros de entrada hacia un clasificador. Mediante una repetición continua de la acción imaginada, el clasificador puede ser entrenado para determinar cuando la acción imaginada por el sujeto es realizada. De manera subsecuente a la fase de entrenamiento, la tarea del clasificador recae en traducir la imaginación motora del sujeto en comandos de un dispositivo específico. Por ejemplo, la elección de una letra en un programa de deletreo. La Ilustración 13 muestra los componentes básicos de una BCI.

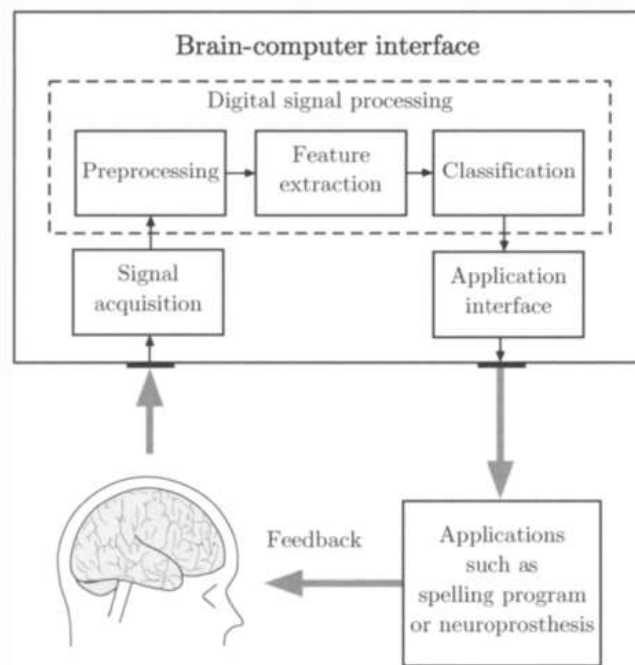


Ilustración 13 Diagrama de Bloques BCI (Sörnmo & Laguna, 2005)

La fase de aprendizaje de BCI no es un procedimiento único, resultando en un clasificador de parámetros fijos, pero debe ser repetido de manera regular. Puesto que el EEG exhibe una variabilidad considerable debido a factores como la hora del día, el nivel hormonal, la fatiga, por lo que es necesario ajustar el clasificador de tal manera que mantenga un rendimiento aceptable. Es importante tener en cuenta la interacción entre los dos controles adaptativos: el cerebro del usuario y el sistema BCI. Ya que el usuario debe mantener una buena correlación entre su intención motora y las características seleccionadas por la BCI. El sistema BCI debe extraer las características que el

usuario sea capaz de controlar de tal manera que pueden convertirse en comandos correctamente(Sörnmo & Laguna, 2005).

La técnica más común para extracción de característica de una señal EEG es analizar el poder espectral en diferentes bandas de frecuencia. Se recomienda el análisis multicanales ya que permite contar con diferentes variaciones espaciales asociadas a distintos tipos de imaginación motora. Por ejemplo, la diferencia entre ambos hemisferios puede explotar el uso de análisis multicanal. Es de vital importancia seleccionar las bandas de frecuencia de tal manera que estas reflejen los ritmos de interés en el EEG. (Sörnmo & Laguna, 2005)

El rendimiento de una BCI puede ser medido en términos de la tasa de información transferida y está definida en bits por minuto. El rendimiento depende de la precisión con los que los estados “imaginativos” son clasificados. Con el fin de mostrar un panorama del rendimiento de un BCI, un sistema con cierto nivel de sofisticación no es capaz de descifrar más de 10-25 bit por minuto. Una información transferida a dicha tasa es capaz de escribir aproximadamente dos palabras en un sujeto completamente paralizado. No obstante, esta tasa puede variar dada la complejidad de los movimientos o la interacción con la neuro-prótesis, haciéndolo más lento. O por el contrario más rápido en el caso de uso de microelectrodos por implantación quirúrgica, o bien mediante el uso de la tecnología haciendo uso de nuevos algoritmos, hardware especializado y computación de altas prestaciones o alto rendimiento.

Este enfoque es utilizado para el diseño de BCI basado en análisis de actividad EEG espontanea, de todas maneras un análisis más complejo se requiere cuando se involucran potenciales evocados resultantes de la estimulación sensorial (Sörnmo & Laguna, 2005).

2.1.3. Procesamiento de señales EEG

Las señales EEG disponen de información clínica de importancia, por esta razón es preponderante el desarrollo de métodos de detección y cuantificación objetiva de las características de la señal para facilitar la interpretación visual. La extracción de características relevantes de las señales es crucial cuando el propósito es el diseño de sistemas para la clasificación de EEG. La cancelación de ruido y artefactos es otro requisito importante en el procesamiento de señales EEG pues garantiza un análisis confiable.

El procesamiento de señales EEG abarca tres aspectos de importancia como son el modelamiento de la señal, la eliminación de artefactos, y el análisis de señales estacionarias y no estacionarias. El modelamiento de señales comprende el uso de modelos, en primera medida, estadísticos para el procesamiento de las señales, sirviendo como punto de partida para una descripción detallada mediante métodos más avanzados. La eliminación de artefactos del EEG comprende una serie de métodos para la reducción o cancelación de ruido, producido por señales subyacentes asociadas a procesos fisiológicos originadas por la misma fuente. Del procesamiento de señales EEG surgen además una gran variedad de métodos de análisis espectral para señales estacionarias y no estacionarias.

2.1.3.1. Modelamiento de una señal EEG

2.1.3.1.1. Propiedades estocásticas y determinísticas de las señales

Una pregunta fundamental es acerca de si la señal es determinística o estocástica. Una respuesta a esta pregunta pueda proveer algunas perspectivas acerca de la generación de mecanismos EEG. Pero de igual manera puede tener implicaciones en los métodos apropiados para análisis de señales.

En general no se pueden predecir las características exactas de la señal EEG en términos de amplitud, duración o morfología de cada onda, es por tal motivo que parece muy conveniente ver la señal EEG como la ejecución de un proceso estocástico. Este enfoque gana más preponderancia dado el hecho de que la señal obtenida no es puramente actividad cerebral. De hecho, siempre se encuentra ruido aleatorio, introducido por ejemplo por ruido interno del amplificador o del aparato de digitalización, para lo cual, incluso si la señal EEG pura tuviese propiedades determinísticas a fin de cuentas es razonable considerar la señal EEG como un proceso estocástico (Sörnmo & Laguna, 2005).

De tal manera que el objeto de este estudio tratara la señal como estocástica. Se han realizado esfuerzos considerables para brindar una respuesta cuantitativa al problema estocástico/determinístico. Uno de los más notables es bajo la hipótesis de que el EEG es generado por un sistema dinámico no lineal. La salida de un sistema no lineal es caracterizada como un proceso determinístico que puede exhibir un comportamiento caótico parecido a un proceso estocástico.

No se ha encontrado evidencia que presente que ha sido mejor modelar el EEG como un proceso caótico de naturaleza determinística. Excepto bajo ciertas condiciones como antes y durante una convulsión epiléptica. Con el objetivo un modelamiento de señal preciso, las características del proceso determinístico deberían ser tan complejas de manera que no se podrían distinguir de un proceso estocástico, esto implica que una descripción estocástica del comportamiento del EEG puede ser igualmente apropiada. (Sörnmo & Laguna, 2005)

2.1.3.1.2. Propiedades estocásticas

Para lograr una caracterización de la señal estocástica se usa un enfoque estadístico mediante una Función de densidad de probabilidad (PDF). Asumiendo que las muestras que representan el EEG $x(0), x(1), \dots, x(N - 1)$ representan la señal modelada como un proceso estocástico con valores reales. Es de interés determinar el conjunto de PDF funciones de densidad de probabilidad que caractericen completamente el proceso:

$$p(\mathbf{x}; \vartheta) = p(x(0), x(1), \dots, x(N - 1); \vartheta),$$

Ecuación 1

Donde el vector columna x contiene la muestra EEG de una observación durante el intervalo de $[0, N-1]$

$$x = \begin{bmatrix} x(0) \\ x(1) \\ \vdots \\ x(N - 1) \end{bmatrix}$$

Ecuación 2

La función de densidad de probabilidad $p(\mathbf{x}; \vartheta)$ de la Ecuación 1 abarca un vector ϑ cuyos elementos definen la forma específica de la función. Los elementos son asumidos como determinísticos pero sus valores son desconocidos. Este vector nos provee una información cuantitativa de varias propiedades de la señal. Por ejemplo asumiendo que $p(\mathbf{x}; \vartheta)$ está distribuido de manera uniforme, el vector ϑ contiene la definición de los intervalos de amplitud sobre los cuales las muestras en x son uniformes. Otro ejemplo es la PDF gaussiana donde ϑ incluye el valor promedio y las

propiedades de correlación de x . Por lo tanto, definiendo la ubicación y la distribución del N -dimensional, como una PDF gaussiana en forma de campana.

Un enfoque no paramétrico para determinar $p(x;\vartheta)$ paramétrico es primero calcular la amplitud del histograma de las muestras de EEG observadas e luego realizar una hipótesis acerca de la estructura en particular de $p(x;\vartheta)$. Otro enfoque es asumir que la PDF es conocida a priori basada en cierto conocimiento fisiológico y centrarse en como estimar el parámetro del vector ϑ . Sin tener en consideración el enfoque que se desee elaborar, el asunto de la PDF no tiene una respuesta sencilla. Las propiedades siempre cambiantes del EEG requieren una estructura de PDF de alta complejidad de manera que se pueda tener un modelo preciso de las señales correspondientes a varios estados cerebrales.

Desde la perspectiva de la ingeniería puede resultar sugestivo asumir que la señal EEG es caracterizada por una función de densidad de probabilidad PDF gaussiana multivariada. Considerando que el EEG es registrado en el cerebro, puede ser visto como la sumatoria de las señales de un gran número de individuos de generadores neuronales individuales (“Osciladores”). El teorema del límite central declara que la suma de variables aleatorias independientes en el límite tiene una PDF gaussiana a medida que el número de variables aumenta. Cada variable aleatoria no requiere ser necesariamente gaussiana para que le teorema se mantenga. Los osciladores neuronales están organizados en grupos con una dependencia interna sustancial, ya que es lo que produce la actividad síncrona visible en el EEG. Por lo tanto, inclusive con grupos de generadores neuronales que puedan ser independientes. El teorema del límite central continúa siendo válido. (Sörnmo & Laguna, 2005)

El EEG ha sido estudiado a lo largo de una gran variedad de condiciones, y resultando ser considerado desde un proceso gaussiano hasta un proceso altamente no gaussiano. Por ejemplo, el EEG puede exhibir un comportamiento gaussiano durante actividad sincronizada. Como la presencia del ritmo alpha, mientras que durante la fase REM de sueño se encontraron distribuciones totalmente desviadas a la gaussiana. (Sörnmo & Laguna, 2005) Otros estudios demostraron que el EEG en fase de descanso es gaussiano en un 66%, mientras que el porcentaje cayó al 32% cuando se les solicito a los pacientes realizar alguna operación aritmética (Sörnmo & Laguna, 2005). En general, la amplitud de la distribución se convierte incrementalmente en no gaussiana a medida que el intervalo de la medida aumenta. En un estudio particular se encontró que más del 90% de los intervalos de 1s pueden ser gaussianos. Mientras que menos del 50% cuando el intervalo aumenta a más de 8s (Sörnmo & Laguna, 2005). Se debe resaltar que el procedimiento estadístico usado para testear la tendencia a representar una distribución gaussiana es, en sí, más complicado debido que se deben apreciar ciertas propiedades de las muestras a ser testeadas. Por ejemplo, que las muestras constituyan un conjunto de variables aleatorias estadísticamente independientes.

A pesar de sus variaciones desde el punto de vista de análisis espectral la PDF que tienda a ser gaussiana, es una de las principales herramientas en el análisis EEG. Ya que se tiene una conexión natural con esta distribución. De manera general la PDF gaussiana multivariada de un proceso estocástico $x(n)$, está completamente caracterizado por su valor promedio.

$$m_x(n) = E[x(n)]$$

Ecuación 3

Y la función de correlación o auto correlación:

$$r_x(n_1, n_2) = E[x(n_1), x(n_2)]$$

Ecuación 4

Estas ecuaciones reflejan la dependencia entre dos muestras $x(n_1)$ y $x(n_2)$ y que denota la función de correlación simétrica $r_x(n_1, n_2)$. Por ejemplo $r_x(n_1, n_2) = r_x(n_2, n_1)$. En general el proceso $x(n)$, no es estacionario desde que se define en la Ecuación 3 y la Ecuación 4 como funciones dependientes del tiempo y por esta manera pueden diferir entre cada muestra.

Usando notación de vectores y matrices, el vector promedio y la matriz de correlación pueden ser definidas de manera compacta:

$$m_x = E[x]$$

Ecuación 5

Y

$$R_x = E[xx^T]$$

$$R_x = \begin{bmatrix} r_x(0,0) & \cdots & r_x(0, N-1) \\ \vdots & \ddots & \vdots \\ r_x(N-1, 0) & \cdots & r_x(N-1, N-1) \end{bmatrix}$$

Ecuación 6

Respectivamente. Estas dos cantidades caracterizan la PDF gaussiana multivariada.

$$p(x) = \frac{1}{2\pi^{N/2} |C_x|^{1/2}} \exp \left[-\frac{1}{2} (x - m_x)^T C_x^{-1} (x - m_x) \right]$$

Ecuación 7

Donde la matriz C_x describe la covarianza y está relacionada con la matriz de correlación R_x de la siguiente manera:

$$C_x = E [(x - m_x)(x - m_x)^T] = R_x - m_x m_x^T$$

Ecuación 8

La relación entre C_x y R_x son idénticas cuando $x(n)$ es un proceso con media igual a 0. Por ejemplo, si $m_x = 0^2$.⁴

Para el modelo gaussiano de arriba, la información esencial en propiedades de la señal está contenida en la matriz de correlación R_x , y de manera acorde R_x juega un papel importante en la analítica de señales EEG. Se espera que R_x transmita información fisiológica de importancia, por ejemplo, un estado cerebral en particular. Sin embargo, la matriz R_x , dada en su forma más general en la Ecuación 6, es difícil estimar de manera confiable con una sola recolección de datos pues la estimación de cada entrada $r_x(n_1, n_2)$ se encuentra basado solamente en dos muestras. Por ejemplo $x(n_1)$ y $x(n_2)$. Por lo tanto, la estimación resultante tendrá una varianza inaceptablemente larga; la varianza puede ser reducida, si se encuentran disponibles varias realizaciones pueden ser usadas para promediar en conjunto.

4 Las matrices C_x y R_x como las matrices de covarianza y correlación respectivamente. Estas matrices son de particular importancia cuando se estudian señales repetitivas.

En muchas situaciones sin embargo es válido asumir que el EEG tiene ciertas propiedades restrictivas, por ejemplo, viendo la señal como un proceso estacionario, como un proceso con propiedades de cambio en la correlación de manera lenta, o como la salida de un sistema lineal, invariante en el tiempo, orientado a ruido aleatorio. La introducción de tales restricciones implica que no solamente R_x llegaría a ser más estructurada, y por lo tanto más sencilla de estimar, pero tal vez más importante es que la información contenida en R_x puede brindar una interpretación intuitiva.

Estacionariedad: Una propiedad importante de los procesos estocásticos, es cuando sus propiedades estadísticas son asumidas como invariantes en el tiempo. Dichos procesos se le conoce como estacionario. Se detalle un interés particular en los procesos estacionarios de sentido amplio. Ya que solo es necesario considerar los dos primeros momentos del proceso. Por ejemplo, una PDF en la Ecuación 7. Un proceso $x(n)$ es estacionario de sentido amplio si su función promedio $m_x(n)$ es igual a una constante m_x para todos los instantes n .

$$m_x(n) = m_x$$

Ecuación 9

Y su función de correlación $r_x(n_1, n_2)$ es una función solamente de retraso de tiempo $k = n_1 - n_2$ entre dos muestras $x(n_1)$ y $x(n_2)$. Por ejemplo $r_x(n, n - k) = r_x(k)$ la función de correlación dependiente del retraso se encuentra denotada por:

$$r_x(k) = E [x(n)x(n - k)]$$

Ecuación 10

La correspondiente matriz de correlación se encuentra definida de la siguiente manera:

$$r_x = \begin{bmatrix} r_x(0) & \cdots & r_x(-N+1) \\ \vdots & \ddots & \vdots \\ r_x(N-1) & \cdots & r_x \end{bmatrix}$$

Ecuación 11

A parte de ser simétrica, hay que recordar que $r_x(-k) = r_x(k)$ para un proceso con valores reales. La matriz de correlación en la Ecuación 11 es una matriz de toeplitz ya que todos sus elementos a partir de la diagonal son idénticos. E igual a la función de correlación bajo cierto retraso de tiempo. La matriz de toeplitz aplica de manera general para matriz de correlación de un proceso estacionario. Esta matriz es de vital importancia en el manejo de algoritmos computacionalmente eficientes para estimación espectral.

La Estacionariedad considerándose las propiedades de los procesos estocásticos, puede expresarse en términos espectrales. Brindando una caracterización más intuitiva que la matriz de correlación. El análisis espectral está íntimamente relacionado con la distribución gaussiana. Ya que el espectro de potencia está definido bajo la transformada discreta de Fourier de tiempo de la función de correlación $r_x(k)$.

$$S_x(e^{j\omega}) = \sum_{n=-\infty}^{\infty} r_x(k)e^{-j\omega k}$$

Ecuación 12

La relación inversa:

$$r_x(k) = \frac{1}{2\pi} \int_{-\pi}^{\pi} S_x(e^{j\omega}) e^{j\omega k} d\omega$$

Ecuación 13

En el análisis EEG, la validación de la Estacionariedad depende del tipo de señal a ser analizada. La actividad normal espontánea es esencialmente estacionaria y por lo tanto sometida de manera común a análisis de potencia espectral. Sin embargo, dadas las consideraciones de gaussianidad y su comportamiento con el incremento de las longitudes de intervalo, la actividad normal espontánea se encuentra razonablemente bien modelada como un proceso estacionario solo para intervalos relativamente cortos de tiempo.

Las técnicas para realizar la estimación del poder espectral basado en Fourier $S_x(e^{j\omega})$ se encuentran descritas en la siguiente sección de Análisis Espectral no Paramétrico donde se abordan algunas de las limitaciones heredadas de estas técnicas. De la misma manera se discute la extracción de características de diferentes componentes espectrales.

No Estacionariedad: Cuando se tienen en cuenta periodos largos de tiempo, muchos factores hacen necesario para tratar una señal EEG no estacionaria, procesos estocásticos. Por ejemplo, un proceso cuya media, función de correlación, y momentos de orden superior varían en el tiempo. Por ejemplo, el grado de conciencia plena de un sujeto puede variar a lo largo del tiempo, causando que las propiedades del ritmo alpha cambie lentamente. Otro factor corresponde a la acción de abrir y cerrar los ojos lo que causa un comportamiento abrupto en la actividad rítmica. Un factor adicional es la ocurrencia intermitente de ondas transitorias como los picos epilépticos o los artefactos que tienen forma de pulso intermitente.

Los que se mencionan más arriba son ejemplos de EEG no estacionario. Se han implementado ciertos enfoques basados en algoritmos para procesar cada uno de estos tipos.

- Las propiedades de las señales que varían de manera lenta en el tiempo pueden ser identificadas por métodos de análisis. Desarrollados originalmente para señales estacionarias a intervalos consecutivos superpuestos. La **transformada corta de Fourier**, es una técnica reconocida debido a que realiza una especie de análisis de “perfilamiento” espectral de la señal, es utilizado en el análisis conjunto tiempo frecuencia. Otro enfoque es diseñar un método tiempo frecuencia el cual se encuentre inherentemente en la capacidad de caracterizar las propiedades espectrales basadas en el tiempo; como la distribución Wigner Ville.

Otra opción es diseñar un modelo paramétrico de la señal EEG y estimar los valores de sus parámetros recursivamente mediante un algoritmo adaptativo. Para este enfoque la salida está hecha de espectros consecutivos que reflejan pequeños cambios en el comportamiento rítmico.

- Actividad que cambia abruptamente, posiblemente sugiriendo transiciones ocurridas durante distintas fases o estados de un comportamiento determinado. Puede ser analizado descomponiendo la señal en series de longitud variable de segmentos cuasi estacionarios,

caracterizados por la media de su espectro de potencia y parámetros espectrales relacionados. El enfoque basado en segmentación del EEG requiere un enfoque que pueda determinar los límites de intervalos apropiados.

- Actividad transitoria, en la forma de puntas y picos se presentan estas ondas no estacionarias claramente visibles. La salida del detector provee la salida para agrupar las señales transitorias de forma similar y caracterizar su patrón de ocurrencia temporal. Las ondas transitorias no se prestan para análisis de frecuencia, pero son descritas mediante varios parámetros de ondas como la amplitud y duración. La técnica de análisis wavelet es muy utilizado en estos ámbitos para potenciales evocados.

Ya que las ondas transitorias están superpuestas en el EEG la salida del detector de salida puede ser usando en cambio para excluir objetos que claramente no se adaptan al análisis espectral.

Señales No gaussianas: Puede llegar a ser necesario desarrollar métodos de análisis que vayan más allá de momentos de segundo orden y que tengan en cuenta propiedades no gaussianas. Esto implica el desarrollo de métodos de orden superior de amplitud de distribución univariada del EEG. Por ejemplo, para obtener un estimado de:

$$E[(x(n) - m_x)^k], k = 3, 4, \dots$$

Ecuación 14

El momento de tercer orden es proporcional al *sesgo* que describe el grado de desviación de la simetría de una PDF gaussiana, mientras que el momento de cuarto orden se encuentra a parte de una constante, proporcional a la *curtosis* de la PDF alrededor del valor promedio m_x .

El método de momento es simple para aplicar a distribuciones univariadas, pero no produce ninguna información en relaciones temporales. La extensión de este método es muy compleja para ser considerada en términos técnicos y conceptuales. La técnica más difundida para estudiar las propiedades no gaussianas del EEG es tomar el acumulado de tercer orden como punto de partida $k_x(k_1, k_2)$ los cuales asumen que $x(n)$ tiene media cero, como proceso estacionario, que refleja la variación conjunta de las tres muestras separados por retrasos definidos por k_1 y k_2 .

$$k_x(k_1, k_2) = E [x(n)x(n - k_1)x(n - k_2)]$$

Ecuación 15

De manera similar a la transformado de Fourier que relaciona la función de correlación $r_x(k)$ al espectro de potencia $S_x(e^{j\omega})$. La transformada de Fourier de dos dimensiones toma en cuenta la relación $k_x(k_1, k_2)$ del biespectro. El biespectro muestra la potencia espectral de dos frecuencias y por lo tanto se usa para detectar la relación entre diferentes frecuencias. Indicando el grado de que una señal siga una distribución gaussiana. Ya que el biespectro es cero si la señal es puramente gaussiana.

2.1.3.1.3. Modelos estocásticos lineales

Esta clase de modelos matemáticos son meramente fenomenológicos y no incorporan información anatómica o fisiológica. Los modelos están diseñados para tener en cuenta ciertos parámetros de referencia de la señal observada. Por ejemplo, determinar si la señal está compuesta de distintos espectros de ancho de banda. El propósito común de estos modelos es derivar parámetros útiles en

términos clínicos. Más que desarrollar un mecanismo que explique los mecanismos subyacentes de la generación de EEG.

La señal EEG es modelada como la salida de un sistema lineal orientado a *Ruido blanco*⁵ estacionario, el cual es asumido generalmente como gaussiano. Ver Ilustración 14. Los parámetros de los valores definidos en el sistema son estimados mediante adaptación del modelo lineal a la señal EEG usando un criterio de error adaptado. Frecuentemente se utiliza el método de error cuadrático medio. Este tipo de métodos son conocidos como modelamiento basado en análisis espectral. Las razones para utilizar este tipo de modelos se describen a continuación:




Ilustración 14 Modelamiento de EEG mediante filtro lineal de ruido blanco $v(n)$, con varianza σ_v^2 . El filtro lineal $H(z)$, el cual es caracterizado por un conjunto de parámetros, da forma espectral al ruido y produce la señal de salida $x(n)$. El espectro de potencia complejo de la señal de salida $x(n)$ esta denotado por $S_x(z)$.

- Puede producir un espectro de potencia el cual es más exacto que el obtenido mediante análisis basado en Fourier.
- La descripción espectral paramétrica consiste en un conjunto de características compactas que pueden ser útiles para la detección y clasificación de varios ritmos EEG.
- Se facilita el desarrollo de ciertos algoritmos espectrales. Por ejemplo detección de actividad epiléptica en ciertos tipos de eventos no estacionarios puede estar basada en la desviación entre el modelo de la señal y la señal observada.
- Los valores de los parámetros estimados pueden servir como base para el diseño de un simulador de EEG. Usando principalmente para pruebas y validación de los algoritmos.

La popularidad de los modelos lineales es explicada parcialmente por modelos computacionales para la estimación de parámetros.

El modelo de auto regresión de movimiento promedio (ARMA) representa la forma general de los modelos lineales estocásticos, definida por la siguiente ecuación diferencial.

⁵ El ruido blanco consiste en una secuencia de media cero, caracterizado por variables aleatorias no correlacionadas, mediante una función de probabilidad de densidad que se ajuste a dicho comportamiento.

$$x(n) = -a_1x(n-1) - \dots - a_px(n-p) + b_0v(n) + \dots + b_qv(n-q)$$

Ecuación 16

Cuando los parámetros del modelo $a_1, \dots, a_p, b_0, \dots, b_q$ son fijos y la entrada $v(n)$ es ruido blanco, con varianza dada por:

$$E[v^2(n)] = \sigma_v^2$$

Ecuación 17

Entonces, la salida de la muestra $x(n)$ es modelada como una combinación lineal de las pasadas p muestras de salida $x(n-1), \dots, x(n-p)$, las pasadas q muestras de entrada $v(n-1), \dots, v(n-q)$ y la muestra de entrada actual $v(n)$.

Usando la transformada z , el modelo ARMA, puede ser descrito de igual manera mediante la función racional de transferencia $H(z)$.

$$H(z) = \frac{B_z}{A_z} = \frac{b_0 + b_1z^{-1} + \dots + b_qz^{-q}}{1 + a_1z^{-1} + \dots + a_pz^{-p}}$$

Ecuación 18

Habiendo estimado los modelos del parámetro $a_1, \dots, a_p, b_0, \dots, b_q$ y σ_v^2 de la señal observada, el espectro de potencia complejo del modelo ARMA puede ser calculado como:

$$S_x(z) = H(z)H(z^{-1})\sigma_v^2$$

Ecuación 19

O el espectro de potencia puede ser calculado mediante evaluación de z en un círculo unitario. Por ejemplo $z = e^{j\omega}$

$$S_x(e^{j\omega}) = |H(e^{j\omega})|^2\sigma_v^2$$

Ecuación 20

Basado en Ilustración 14 el espectro de potencia obtenido de ARMA es:

$$S_x(e^{j\omega}) = \left| \frac{b_0 + b_1e^{-j\omega} + \dots + b_qe^{-j\omega q}}{1 + a_1e^{-j\omega} + \dots + a_pe^{-j\omega p}} \right| \sigma_v^2$$

Ecuación 21

Las principales características del espectro de potencia $S_x(e^{j\omega})$ en la Ecuación 21 están determinado por la ubicación de las raíces de los polinomios $B(z)$ y $A(z)$. Los ceros, dados por $B(z)$ están asociados con valles espectrales, y los polos dados por $A(z)$ están asociados con picos espectrales.

Existen diversos tipos de modelos lineales:

- Modelamiento Auto regresivo (AR)
- Modelamiento Auto regresivo con varianza en el tiempo
- Modelamiento Auto regresivo multivariado.
- Modelamiento Auto regresivo con impulso de entrada

2.1.3.1.4. Modelamiento no lineal de EEG

Aunque el modelamiento lineal presentado más arriba, los modelos de filtro de ruido, con parámetros variantes e invariantes en el tiempo, han sido usados de manera exitosa en muchas aplicaciones EEG. Estos modelos no presentan todos los tipos de patrones de señales, ni tampoco proveen en detalle información acerca de los mecanismos de generación de EEG. Por tal motivo los modelos de simulación no lineal han sido desarrollados con el fin de obtener mejor entendimiento acerca de los procesos subyacentes de generación de EEG. Estos modelos están basados hechos neurofisiológicos y pueden reflejar como diferentes conglomerados de neuronas interactúan entre si descritas como un conjunto de ecuaciones no lineales. Este tipo de modelamiento se encuentra más allá del alcance del presente proyecto.

2.1.3.2. Artefactos en EEG

Uno de los aspectos clave en el procesamiento de señales es descartar en la medida de lo posible el ruido y los artefactos. El procesamiento de artefactos es uno de los aspectos principales en el análisis por computadora de señales biomédicas. Y asume la misma preponderancia de la señal misma extraída del cerebro. En los registros de EEG existen una gran variedad de artefactos que pueden ser identificados de manera sencilla, mientras que otros pueden camuflarse dentro de la actividad cerebral.

La caracterización de los artefactos puede estar dada por su origen, por ejemplos técnicos o fisiológicos, esta categorización es aplicable a otras señales bio eléctricas. Mientras que los artefactos de tipo técnico pueden ser reducidos de drásticamente solo con garantizar la correcta adhesión de los electrodos a la superficie del cuerpo, es imposible evitar la presencia de artefactos de origen fisiológico. Por esta razón la mayoría de los algoritmos implementados para remoción de artefactos se centran en los de origen fisiológico.

2.1.3.2.1. Características de los artefactos

Existen tres tipos de artefactos que no son cerebrales de origen fisiológico como son el parpadeo de ojos, la actividad cardiaca y la actividad muscular. Y hay un cuarto tipo correspondiente al equipamiento y los electrodos con origen técnico. Cabe resaltar que es posible que se presenten ambos tipos de artefactos durante una lectura de EEG. Más aún existen ciertos tipos de artefactos que se pueden encontrar de manera más frecuente bajo cierto tipo de actividad como el sueño.

Movimiento de los ojos y parpadeo: El movimiento de los ojos produce actividad eléctrica, cuando es lo suficiente fuerte puede ser registrada en el EEG. El EOG refleja la actividad realizada entre la córnea y la retina durante el movimiento ocular. La principal interferencia del EOG con la señal depende de la proximidad del electrodo y la dirección hacia la que se esté moviendo del ojo. Las ondas generadas por el parpadeo repetitivo son mostradas en la Ilustración 15 a. aunque el comportamiento repetitivo puede ser fácilmente identificado, el EOG puede ser confundido con actividad lenta del EEG como actividad theta o delta. El movimiento ocular no solo está presente durante fase de actividad consciente también puede estar presente durante el sueño.

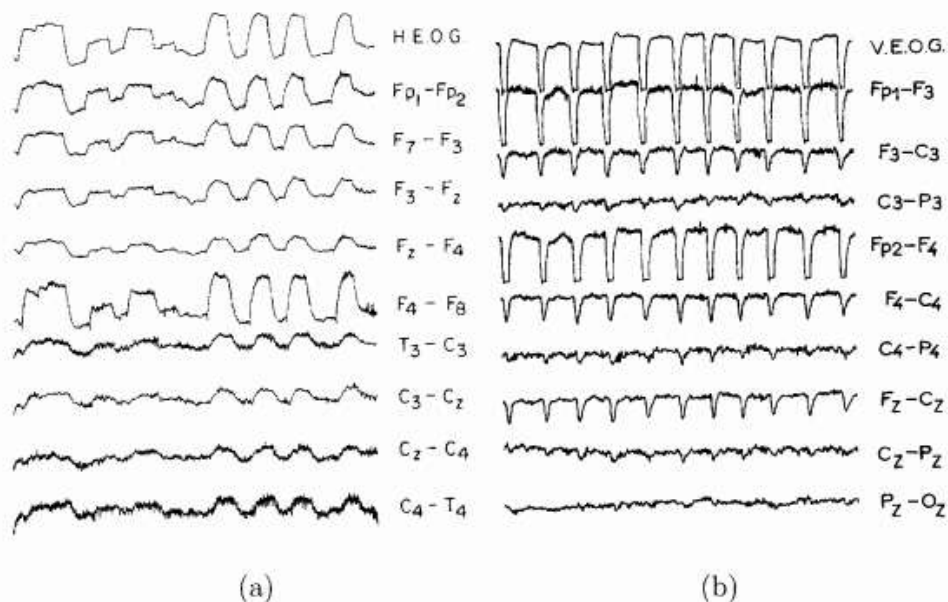


Ilustración 15 Artefactos en EEG causado por (a) movimiento de los ojos parpadeo de los ojos (b) parpadeo voluntario de manera repetitiva. La señal en la primera fila de cada columna muestra el EOG horizontal y vertical respectivamente. (Sörnmo & Laguna, 2005)

Otro artefacto conocido es el parpadeo de los ojos, produce un cambio más abrupto en la forma de la onda, que el EOG, contiene una mayor cantidad de componentes de alta frecuencia, esta característica puede ser apreciada en la Ilustración 15 b. Donde la onda relacionada con los parpadeos repetitivos tiende una forma cuadrada. De la figura se puede observar que la amplitud de los electrodos frontales es sustancialmente mayor que la actividad EEG.

La estrategia para la cancelación de este tipo de artefactos se encuentra basada en utilizar la señal de referencia de los electrodos frontales cerca a los ojos como señales de referencia.

Actividad muscular: Otro artefacto común corresponde a la actividad generada por la contracción muscular, medida en la superficie del cuerpo con Electromiografía EMG, este tipo de artefacto es encontrado en pacientes despiertos al realizar comportamientos como tragar saliva, hacer muecas, fruncir el ceño, masticar, hablar, chupar, e hipo (Sörnmo & Laguna, 2005). La manera general de la forma del EMG depende del grado de contracción del musculo. Una contracción tenue produce un tren de picos de baja amplitud, mientras que un aumento en la fuerza de la contracción disminuye la distancia entre picos de tal manera que el EMG exhibe el comportamiento de una señal continuamente variante. Ilustración 16. La actividad EMG es notablemente reducida en la ausencia de tensión muscular durante la relajación y el sueño.




Ilustración 16 Señal multicanal de EEG que se encuentra contaminada con artefactos producidos por episodios de electromiografía. (Sörnmo & Laguna, 2005)

La cancelación de artefactos por actividad muscular es más compleja que la del EOG ya que se solapa con la actividad beta entre los 15 – 30 Hz. A esto se suma la imposibilidad de adquirir una señal con solo actividad EMG vía EEG que pueda ser útil para la cancelación de artefactos.

Actividad cardiaca: La actividad cardiaca del corazón se ve reflejada por el electrocardiograma ECG, no obstante, la actividad cardiaca presente en los registros de EEG suele ser particularmente baja. (1 - 2, 20-100 μV respectivamente). Puede obstaculizar la actividad EEG en ciertos tipos de fisionómicas como sujetos robustos con cuellos cortos y gruesos, la forma de la onda de patrón regular ayuda a caracterizar los latidos del corazón en condiciones normales, siendo muy útil en la cancelación de artefactos. Aunque en algunos casos las formas de pico pueden confundirse durante ataques epilépticos, y también en la presencia de arritmias cardiacas exhibiendo una amplia variación en el intervalo entre latidos.

Electrodos y equipamiento: El artefacto “electrodo-pop” de su traducción al español, se encuentra basado en la manifestación del contacto de la corriente directa DC con la interacción del electrodo sobre la piel. Se puede presentar en cualquier tipo de señal bio eléctrica, y es manifestado por un cambio abrupto sobre la línea base seguido por una reincorporación gradual a la misma. En ocasiones puede ser confundido con ondas en pico.

Otro tipo de artefacto que ser posible es mediante el cable que conecta el dispositivo, ya que si el cable no cuenta con la adecuada cobertura lo hace susceptible a ruido electromagnético causado por corrientes de dispositivos electrónicos cercanos, como resultado una interferencia de potencia de 50 a 60 Hz es concentrada en los electrodos contaminando la señal EEG.

Finalmente, los artefactos relacionados con el equipamiento como ruido interno de los amplificadores y recorte de amplitud causado por los conversores análogo – digital con rango dinámico muy estrecho.

2.5.2.2. Procesamiento de artefactos

El procesamiento de artefactos abarca desde el rechazo de artefactos en el cual un marcador es creado para identificar el artefacto, a la cancelación completa de los artefactos de la señal EEG. El rechazo de artefactos es el enfoque más crudo ya que solo busca rechazar los segmentos de baja

calidad. Sin embargo, se debe tener en cuenta sin importar la técnica empleada en que se debe retener la mayor cantidad de datos posible.

La cancelación de artefactos depende del contexto en el que es usado el algoritmo, por ejemplo, la cancelación de artefactos para la lectura visual donde se desea conservar la mayor cantidad de información clínica posible durante el proceso de cancelación. Esta demanda puede ser disminuida en caso de que la cancelación de ruido sea un proceso intermedio. En cualquier caso, es necesario que el desarrollo de algoritmos este acompañado de validación visual. Para asegurar un rendimiento aceptable.

En esta sección el procesamiento de artefactos es sinónimo de la etapa de **preprocesamiento**, lo que condiciona la señal EEG para el análisis subsiguiente. Sin embargo, la cancelación de artefactos puede estar presente en otras etapas del análisis. Por ejemplo, un método para la estimación espectral del EEG puede ser más robusto antes la presencia de un sonido impulsivo. Otro ejemplo es el promedio ponderado que puede ser utilizado en potenciales evocados.

Otro enfoque es estimar el ruido $v(n)$ de una señal medida en el cráneo contra otra de referencia. Y luego sustraer el estimado de la señal observada $x(n)$. Este enfoque asume implícitamente que $x(n)$ puede ser dividido en la suma de la actividad cerebral y el ruido.

$$x(n) = s(n) + v(n)$$

Ecuación 22

Una vez se conoce dicha suposición, toma sentido estimar $s(n)$ sustrayendo el ruido estimado $\hat{v}(n)$ de $x(n)$. Este tipo de método se encuentra asociado con los métodos de sustracción, pero también recae sobre la reducción de ruido lograda a través de filtros lineales de $x(n)$.

La popularidad de los modelos aditivos es explicada por su simplicidad y por el amplio rango de métodos desarrollados para la estimación óptima de $s(n)$. Es necesario aclarar que no necesariamente este es el único modelo apropiado pues existen otros tipos de modelos que asumen la señal y el ruido interactuando de manera multiplicativa.

$$x(n) = s(n)v(n)$$

Ecuación 23

Existen diversas estrategias para la cancelación de artefactos como son:

- Reducción de artefactos utilizando filtros lineales.
- Cancelación de artefactos usando linealidad combinado con señales de referencia.
- Cancelación adaptativa de artefactos usando linealidad combinado con señales de referencia.
- Cancelación de Artefactos Usando Señales de Referencia Filtradas.

2.1.3.3. *Análisis Espectral no Paramétrico*

El análisis espectral es una técnica poderosa para un amplio rango de señales médicas. De manera preliminar esta técnica se utilizó para proveer una caracterización más detallada de la actividad EEG, de la que puede ser alcanzada con técnicas de análisis unidimensionales como los histogramas de las muestras. Considerando el comportamiento oscilatorio de las muestras de muchos ritmos EEG, en términos de descomposición de las señales en senos y cosenos desde una perspectiva

computacional. El análisis espectral basado en la transformada de Fourier esencialmente correlaciona la señal en términos de senos y cosenos de varias frecuencias y produce un conjunto de coeficientes que definen el espectro de potencia. La potencia de una banda de frecuencia en particular es fácilmente obtenida a partir del espectro y entre muchas cosas puede ser usado para determinar cuando el ritmo alpha se encuentra presente o no en una lectura de EEG. El análisis espectral basado en Fourier se refiere comúnmente como análisis espectral no paramétrico ya que el modelamiento no paramétrico, ya que no hay supuestos de modelado paramétrico respecto a la señal que estén incorporados.

De la Ecuación 12 se resalta que $S_x(e^{j\omega})$ es una cantidad natural para caracterizar una señal gaussiana estacionaria, ya que $S_x(e^{j\omega})$ está definida como la transformada de Fourier de $r_x(k)$. El poder espectral también puede utilizarse como una medida para medir señales estacionarias no gaussianas. A pesar de que no proveen una caracterización completa. Si bien hay procedimientos estadísticos para caracterizar una señal como estacionaria, el análisis espectral es tomado en consideración de manera general para señales capturadas, durante la generación de actividad normal y espontánea de vigilia en estado de reposo. Teniendo en cuenta duraciones relativamente cortas de tiempo aproximadamente de 10 segundos, las cuales se encuentran libres de artefactos,

2.1.3.3.1. Análisis de potencia espectral basado en Fourier

A continuación, se explica la estimación de potencia espectral no paramétrica basada en la Transformada de Fourier en tiempo discreto. De la Ecuación 12 podemos obtener que el poder espectral de una señal estacionaria $x(n)$ está definido por:

$$S_x(e^{j\omega}) = \sum_{n=-\infty}^{\infty} r_x(k)e^{-j\omega k}$$

Donde $r_x(k)$ denota la función de correlación que caracteriza las muestras $x(0), \dots, x(N-1)$. Antes $S_x(e^{j\omega})$ podía ser calculado, $r_x(k)$ tenía que ser estimado de $x(n)$ pues en la práctica es desconocido. Asumiendo que la señal observada sea una correlación ergódica⁶, la estimación es lograda de manera regular mediante el uso del siguiente estimador de tiempo promedio.

$$\hat{r}_x(k) = \frac{1}{N} \sum_{n=0}^{N-1-k} x(n+k)x(n), \quad k = 0, \dots, N-1$$

Ecuación 24

6 En procesamiento de señales un proceso estocástico, es **ergódico** si las propiedades estadísticas de una muestra pueden ser deducidas de una sola muestra, lo suficientemente larga obtenida de manera aleatoria del proceso.

Donde los retrasos negativos son obtenidos de la propiedad simétrica, por ejemplo: $\hat{r}_x(k) = \hat{r}_x(-k)$. Combinando la definición de poder espectral con la función de correlación estimada en la Ecuación 24, un estimado de la potencia espectral puede ser obtenida de:

$$\hat{S}_x(e^{j\omega}) = \sum_{k=-N+1}^{N-1} \hat{r}_x(k) e^{-j\omega k}$$

Ecuación 25

También conocida como *Periodograma*.

Donde la señal $x(n)$ solo aparece de manera implícita en la Ecuación 25, es sencillo derivar una expresión en la cual explícitamente se muestre como $\hat{S}_x(e^{j\omega})$ está relacionado con $x(n)$. Esto se cumple en primera medida notando que $\hat{r}_x(k)$ en la Ecuación 24 puede ser expresado como una convolución de $x(n)$ y su contraparte es inversa en el tiempo.

$$\hat{r}_x(k) = \frac{1}{N} x(k) * x(-k)$$

Ecuación 26

Donde $x(n)$ es asumido como cero fuera del intervalo $[0, N-1]$, y $\hat{r}_x(k)$ es simétrica, por ejemplo $\hat{r}_x(k) = \hat{r}_x(-k)$. Tomando la transformada de Fourier de la convolución, tenemos que:

$$\hat{S}_x(e^{j\omega}) = \frac{1}{N} |X(e^{j\omega})|^2 = \frac{1}{N} \left| \sum_{n=0}^{N-1} x(n) e^{-j\omega n} \right|^2$$

Ecuación 27

Por lo tanto, el espectro de poder es estimado mediante simple cálculo de la magnitud cuadrada del punto N DTFT de $x(n)$ e implementado de manera eficiente mediante el algoritmo de FFT.




Ilustración 17 Análisis espectral de un EEG con ritmo Alpha . (a) El poder espectral obtenido sin segmentación (N=1024) y (b) con segmentación usando N= 256 y sobre posición de segmentos de 128 muestras. El pico espectral relacionado con el ritmo alpha es más discernida más fácilmente (b). Los picos estrechos que están por encima de 10Hz en (a) más o menos desaparecen con la segmentación introducida. La señal EEG analizada se muestra en la parte inferior y contiene prominentemente ritmo alpha. Caracterizado en estados de relajación y/o meditación. (Sörnmo & Laguna, 2005)

La Ilustración 17 muestra el análisis espectral basado en Fourier de una señal EEG que contiene una fuerte presencia de ritmo alpha. Basado en el análisis de Periodograma mediante una técnica conocida como ventana de Bartlet, el espectro de potencia es calculado sin el promedio de segmento o con un promedio de segmentos superpuestos. Aunque bien el espectro de potencia de la Ilustración 17 (a) (a, arriba a la izquierda) tiene una varianza más grande que la gráfica (b) de la derecha; Cuando el propósito es resolver picos estrechamente espaciados es mejor obtener resolución espectral; esto no es posible cuando el poder espectral es obtenido mediante promedio. Se destaca de manera obvia que ninguna de las dos estimaciones de poder espectral se puede destacar como superior o mejor que la otra.

2.1.3.3.2. Parámetros espectrales

El análisis espectral no paramétrico es la columna central de muchos sistemas de análisis de EEG. La potencia o poder espectral resultante no es de fácil interpretación, pero casi siempre debe condensarse en un conjunto compacto de parámetros representativos más adecuados para investigaciones de carácter cuantitativo, como clasificación y post procesamiento estadístico. El proceso de **extracción de características** se vuelve aún más importante cuando se considera grandes volúmenes de datos contenidos en grabaciones de EEG multicanal. Este conjunto de parámetros describe características prominentes del espectro. Como amplitudes de picos y sus

respectivas frecuencias. Los parámetros espectrales más usados se describen a continuación (Sörnmo & Laguna, 2005):

Los parámetros espectrales han sido usando ampliamente en diferentes aplicaciones EEG. Que va desde su uso médico en desordenes de sueño, isquemia cerebral, epilepsia, monitoreo de cirugía (Sörnmo & Laguna, 2005), hasta su uso reciente en términos de investigación del cerebro y la conciencia (Ekman et al., 2005) , pasando por ámbitos de nuevas interfaces cerebro computador mediante neuro implantes (Neuralink, n.d.).

El primer paso del desarrollo de los parámetros espectrales es evaluar las propiedades del poder de espectro estimado usando algún formato de representación gráfica que se adapte. Este análisis visual es de vital importancia para juzgar cuan representativo es un parámetro en la descripción de cierta propiedad espectral. Este ejercicio también es también aporta conocimiento de la señal en la medida que se puede comprender cuanto la señal distorsiona el espectro de poder.

Una decisión básica acerca de cuándo la potencia espectral debe ser analizada y presentada en función de una escala logarítmica o lineal. Esta decisión es guiada por el alcance del análisis: Una escala logarítmica cuando se usan ritmos EEG desincronizados con baja amplitud son de interés primario. La Ilustración 18 muestra el uso de las escalas lineal y logarítmica para su representación gráfica. De hecho, los parámetros espectrales presentados a continuación utilizan ambas escalas.

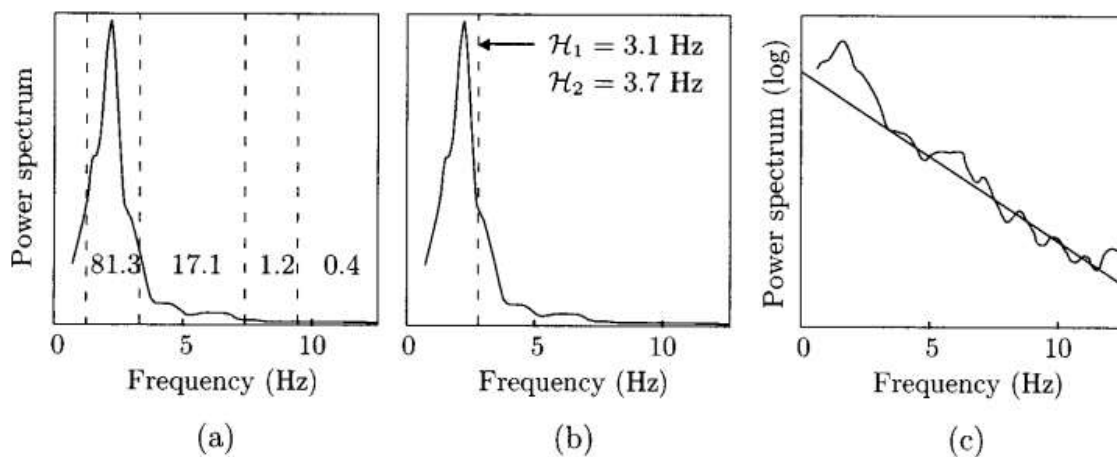


Ilustración 18 La potencia espectral del EEG y sus parámetros relacionados (a) Potencia relativa en las cuatro bandas de frecuencia delta, theta y alpha dividida en dos frecuencias. (b) Los parámetros de movilidad Hjorth H_1 y complejidad H_2 y (c) la pendiente espectral estimada de a partir de la potencia espectral logarítmica. La muestra proviene de un niño con un tumor del tronco encefálico y está dominado por actividad rítmica reflejada por el valor de H_1 de 3,1 Hz (Sörnmo & Laguna, 2005)

Potencia en bandas de frecuencia: El poder absoluto puede ser calculado en bandas de frecuencia cuyos límites se encuentran determinados por convención clínica. (Como se describe en Ondas y ritmos EEG) o mediante perfilamiento estadístico que indica las bandas más importantes.

De manera alternativa puede ser más apropiado calcular la potencia relativa, definida como la razón o proporción de potencia en una sola banda de frecuencia ya bien sea la potencia total $r_x(0)$ o la potencia contenida en ciertas bandas, Ver la Ilustración 18 (a). La razón de potencia en diferentes bandas de frecuencia puede ser diseñada para reflejar la relación entre actividad EEG rápida y lenta para poder caracterizar el grado de anormalidad. Además, las medidas de potencia relativa definen

pueden ser mejores que las absolutas ya que la potencia es influida por factores no fisiológicos como el espesor del cráneo. Una desventaja de las medidas de potencia en bandas de frecuencia fijas es que se vuelven menos representativas cuando hay un pico que está localizado en un límite, para solucionar este problema se utiliza identificación de los picos del espectro.

Frecuencia de los picos: Se logra mediante la identificación de los picos más prominentes. Los picos espectrales se identifican mediante parámetros como frecuencia, amplitud y ancho de banda. Típicamente se utiliza criterio ad hoc para determinar si es un pico de sus circundantes o pertenece a un segundo plano. A parte de la posibilidad de realizar la frecuencia de los picos usando la ubicación del máximo, se utilizan otras técnicas como la mediana o frecuencia media de cada pico individual para realizar dichas estimaciones.

Pendiente espectral: El poder espectral de actividad EEG espontánea está compuesta por dos componentes:

$$S_x(e^{j\omega}) = S_x^r(e^{j\omega})S_x^a(e^{j\omega}),$$

Ecuación 28

Donde $S_x^r(e^{j\omega})$ representa la actividad rítmica y $S_x^a(e^{j\omega})$ representa la actividad no estructurada, con actividad de apariencia irregular. Dado que el componente de actividad irregular tiende a caer de manera exponencial a medida que la frecuencia aumenta. El logaritmo del poder espectral puede ser aproximado por el siguiente modelo:

$$\log S_x(e^{j\omega}) \approx \log S_x^r(e^{j\omega}) + b|\omega|$$

Ecuación 29

Donde b es un parámetro con valor negativo. Para encontrar la pendiente espectral de b se debe encontrar un valor particular de b que minimice el error de mínimos cuadrados $\tau(b)$ entre $\log S_x(e^{j\omega})$ y la pendiente $b|\omega|$.

$$\tau(b) = \int_{-\pi}^{\pi} (\log S_x(e^{j\omega}) - b|\omega|)^2 d\omega$$

Ecuación 30

El cálculo de esta integral está basado en la transformada discreta de Fourier en la cual la frecuencia variable ω ha sido cuantificada. La integral es reemplazada por la sumatoria de las frecuencias discretas. El parámetro resultante \hat{b} ha sido sugerido como un parámetro clínico para cuantificar la actividad EEG y la tasa de decaimiento de componentes de alta frecuencia. Ver Ilustración 18 (c).

Descriptores Hjorth: Consiste en extraer las características espectrales calculando los momentos del espectro de poder $S_x(e^{j\omega})$ originalmente sugerida por Hjorth. (Hjorth, 1970). El n -ésimo momento de orden espectral $\overline{\omega}_n$ está definido por la siguiente integral

$$\overline{\omega}_n = \int_{-\pi}^{\pi} \omega^n S_x(e^{j\omega}) d\omega$$

Ecuación 31

Los momentos impares son idénticos a cero porque el poder espectral es una función simétrica. Por ejemplo $S_x(e^{j\omega}) = S_x(e^{-j\omega})$. Los descriptores de Hjorth están estrechamente relacionados con los momentos espectrales numerados como par.

Existen tres descriptores de Hjorth:

Actividad: Definido por la potencia total de la señal.

Movilidad: Refleja la potencia dominante de $x(n)$ y está definido como la raíz cuadrada del momento de segundo orden normalizado.

Complejidad: Corresponde al momento de cuarto orden $\overline{w_4}$, es usado para definir una medida relacionada con el ancho de banda de $x(n)$.

Índice de pureza espectral: El índice de pureza espectral (SPI) es un parámetro heurístico para el estudio de ciertas señales EEG (Barlow John, 1993) es parámetro está diseñado para reflejar el ancho de banda y está relacionado con el descriptor de complejidad de Hjorth. Está definido como la razón entre el cuadrado del momento de segundo orden en marcha y la potencia total en marcha y el momento de cuarto orden.

$$SPI = \frac{\overline{w_2^2(n)}}{\overline{w_0(n)}\overline{w_4(n)}}$$

Ecuación 32

El término “pureza” hace referencia a que tan bien ha sido analizada una señal descrita por una sola frecuencia: El SPI es igual a una unidad libre de ruido, con forma sinusoidal y decreciente a cero a medida que el ancho de banda aumenta. Los descriptores de Hjorth son igualmente válidos para SPI ya que están basados en señales derivadas. El SPI es más susceptible a ruido ya que su definición implica la razón entre la primera y la segunda derivada.




Ilustración 19 EEG mostrando el ritmo alpha. La señal está caracterizada por tres diferentes tendencias obtenidas como promedios corrientes de la actividad $H_0(n)$ (primer descriptor de Hjorht), la movilidad $H_1(n)$, y el índice de pureza espectral τ_{SPI} (Sörnmo & Laguna, 2005)

2.1.3.4. Segmentación del EEG

Usualmente a las técnicas de modelamiento basadas en análisis espectral, se le añade una etapa de validación adicional con el fin de validar que no existan segmentos con “eventos no estacionarios”. Con el fin de realizar análisis automatizados de las señales EEG, se utilizan técnicas que dividen el EEG en segmentos de tal manera que los segmentos con *características similares* se puedan agrupar conjuntamente. La salida de este método provee una descripción cuantitativa y compacta del registro completo de EEG y puede ser utilizado para un análisis subsecuente a nivel neurofisiológicos. Que para el caso particular de esta investigación con mind wandering tendrá un análisis subsecuente mediante redes neuronales o cualquier otra técnica de clasificación y aprendizaje para evaluación de los registros. En particular, la segmentación puede facilitar el descubrimiento de episodios breves y significativos desde el punto de vista del diagnóstico en los registros de EEG a largo plazo, que de otro modo podrían haberse pasado por alto durante el escrutinio visual(Sörnmo & Laguna, 2005).

Uno de los enfoques más populares para resolver el problema de segmentación se encuentra basado en presunción de que el EEG está compuesto de una serie de segmentos consecutivos de longitud variable, cada uno con propiedades de señales estacionarias. Basado en métodos estadísticos de segundo orden como las propiedades espectrales es posible detectar cambios en la señal EEG. Sea bien en términos de una descripción no paramétrica o basada en modelos. La detección de cambios requiere dos ventanas de tiempo: la ventana de *referencia* y la ventana de

prueba. Un estimado estadístico de la señal es obtenido de la ventana de referencia y comparados con la medida estadística obtenida de la ventana deslizante de prueba, por medio de una *medida de disimilitud*. Denotada como $\Delta(n)$. La ventana de referencia puede ser de tamaño fijo o puede incrementar a medida que no se detecten cambios, mientras que la ventana deslizante se mantiene de tamaño fijo, ver Ilustración 20. La medida de $\Delta(n)$ refleja los cambios en las estadísticas de la señal entre la referencia y la ventana de prueba y está diseñada para que permanezca en un nivel constante hasta que se produzca un cambio, después de lo cual $\Delta(n)$ aumenta rápidamente. Se detecta un límite de segmento en un momento $n = n_1$ cuando $\Delta(n)$ excede el nivel de umbral ϑ ,

$$\Delta(n_1) < \vartheta$$

Ecuación 33

Una vez que se ha detectado un límite, el procedimiento de segmentación se reinicia redefiniendo la ventana de prueba como la ventana de referencia, y se define una nueva ventana de prueba después de la ventana de referencia. El criterio de la Ecuación 33 a menudo se combina con otra prueba en la que se requiere que $\Delta(n)$ supere el umbral ϑ durante un cierto período antes de que se declare un límite como detectado.

Al diseñar un algoritmo para detectar cambios en las propiedades de la señal de EEG, Se deben considerar varios aspectos.

La actividad debe permanecer estacionaria durante al menos un segundo para permitir una estimación precisa de los parámetros.

Un cambio debe ser lo suficientemente abrupto para ser detectado.

El rendimiento del detector también debe estudiarse en términos teóricos. Así como mediante señales simuladas

Dos métodos para la segmentación de EEG que implican pruebas sobre cambios espectrales son: Error de medida espectral – El enfoque de periodograma y Error de medida espectral – El enfoque “Whitening”. (Sörnmo & Laguna, 2005)




Ilustración 20 Principios de segmentación de EEG basados en (a) Ventanas de referencia y de prueba fijas y (b) Ventana de tamaño incremental y ventana de prueba de tamaño fijo. La diferencia en propiedades espectrales de dos ventanas constituye las bases para la detección de cambios (Sörnmo & Laguna, 2005)

2.1.4. Inteligencia Artificial y Aprendizaje Automático

El advenimiento de la inteligencia artificial y el uso de técnicas de aprendizaje automático como una área particular de la IA, han permitido que el procesamiento de señales EEG tenga un complemento desde la perspectiva analítica que optimice el uso de los datos.

2.1.4.1. Inteligencia Artificial

La inteligencia es el estudio de agentes que perciben el mundo a su alrededor, realizan planes y toman decisiones para alcanzar sus objetivos. Se encuentra basada en las matemáticas, la lógica, filosofía, probabilidad, lingüística, neurociencia y teoría de decisiones, muchos campos recaen el alcance de la Inteligencia Artificial IA como lo son la visión por computadora, la robótica, el mismo Aprendizaje Automático y el procesamiento de lenguaje natural (Maini, 2017).

La inteligencia artificial en la actualidad con sus aplicaciones más comunes, como el reconocimiento de caracteres, los chatbots, los jugadores inteligentes, entre otros abarca en el campo de la inteligencia artificial reducida (artificial narrow intelligence (ANI)) que puede realizar una tarea específicamente definida. Sin embargo, la inteligencia artificial general (artificial general intelligence (AGI)), Este tipo de inteligencia realiza actividades intelectuales como un humano incluyendo aprendizaje, comunicación en lenguaje natural o inclusive reprogramarse a sí misma.

2.1.4.2. Aprendizaje Automático (Machine Learning)

"Se dice que un programa de computadora aprende de la experiencia E con respecto a alguna tarea T y alguna medida de desempeño P, si su desempeño en T, medido por P, mejora con la experiencia E." (Mitchell, 1997).

El Aprendizaje Automático AA o Machine Learning ML es una subtarea de la IA, cuyo objetivo es permitirles a los computadores aprender de ellos mismos y por su propia cuenta a través de la *experiencia*. Un algoritmo de ML usa métodos computacionales para *aprender* de los datos

directamente sin depender de ninguna ecuación o modelo. En otras palabras, permite identificar patrones en los datos observados, construir modelos que expliquen el mundo y realizar predicciones sin haber tenido reglas o modelos explícitamente programados. El rendimiento de los algoritmos puede mejorar adaptativamente a medida que se aumenta el número de muestras disponibles para el proceso de aprendizaje (Maini, 2017).



Ilustración 21 El Aprendizaje Automático es una de las subáreas de la inteligencia artificial concerniente a la manera como los computadores aprenden de la experiencia para mejorar su habilidad de planear, pensar, decidir y actuar. Tomado de (Maini, 2017)

El aprendizaje supervisado, no supervisado y reforzado, son básicamente una descripción acerca de cómo los algoritmos pueden abordar los datos. La maquinas también pueden tener cualquiera de los siguientes comportamientos:

2.1.4.2.1. Aprendizaje Supervisado

Con el aprendizaje supervisado, uno mismo alimenta la salida del algoritmo dentro del sistema. Esto significa que, en el aprendizaje supervisado, la maquina ya conoce la salida del algoritmo antes de que comience la tarea de aprendizaje. Un ejemplo básico de este concepto podría ser el aprendizaje de estudiante en un curso impartido por un instructor. Los estudiantes deben saber qué es lo que están aprendiendo acerca del curso.

Conociendo la salida del algoritmo. Todo el sistema necesita saber cómo ejecutar el proceso o los pasos necesarios para alcanzar la salida a partir de la entrada. El algoritmo es enseñado a través de un set de entrenamiento que orienta la máquina. Si el proceso se vuelve desorientado y el algoritmo retorna con resultados totalmente diferentes de los esperados, entonces los datos de entrenamiento hacen su trabajo de guiar el algoritmo al camino correcto.

El aprendizaje supervisado actualmente conforma la mayoría de los sistemas de ML usados alrededor del mundo. La entrada la variable (x) es usada para conectar la variable salida (y) a través de la ejecución del algoritmo. Tanto la entrada, como la salida, como el algoritmo y el escenario son provistos por humanos. El aprendizaje supervisado se puede entender en de una mejor manera, dándole un vistazo a dos tipos de problemas.

Clasificación: Los problemas de clasificación categorizan todas las variables que conforman la salida. Un ejemplo de estas categorías está formado por la clasificación que puede incluirá datos

demográficos, como el estatus marital, sexo, edad. El modelo más común utilizado para este tipo de categoría es el Support Vector Machine. Las Maquinas de Soporte Vectorial se desarrollan para definir los límites de decisión lineales.

Regresión: Los problemas clasificados como regresión incluyen tipos para los cuales las variables de salida es un número real. El formato de este problema a menudo se da en un formato lineal.

2.1.4.2.2. Aprendizaje no supervisado

El concepto de aprendizaje no supervisado no se encuentra tan masificado como el aprendizaje supervisado. De hecho, el concepto ha sido solo aplicado a un número de limitado de aplicaciones hasta ahora .

Durante el proceso de aprendizaje no supervisado, el sistema no es provisto de sets de datos concretos, y las salidas de la mayoría de los problemas son aún desconocidas. En terminología simple, El sistema de AI y el objetivo del ML se encuentra ciego cuando realiza la operación. El sistema posee precisas y robustamente lógicas para guiarse a través de su ejecución. Pero la falta de una entrada y salida apropiada en el algoritmo hace el proceso aún más retador. Aunque parezca un poco increíble, el aprendizaje no supervisado tiene la habilidad de interpretar y encontrar las soluciones a grandes cantidades de datos, a través de los datos de entrada y el mecanismo lógico binario presente en todos los computadores. El sistema carece de cualquier dato de referencia.

Para considerar un ejemplo supongamos que disponemos de una imagen digital que contiene una variedad figuras geométricas coloreadas. Estas figuras geométricas necesitan coincidir con los grupos con base a las características de clasificación como el color. Para un sistema basado en aprendizaje supervisado es un poco más sencillo, pues consiste en enseñarle al computador los detalles pertenecientes a las figuras como que las siluetas con cuatro esquinas son cuadrados y otras con ocho lados son conocidas como octágonos, etc. También es posible enseñarle al sistema a interpretar los colores y ver como la luz reflejada sobre estos objetos es clasificada.

Sin embargo, en aprendizaje no supervisado, el proceso es un poco más complejo, el algoritmo para aprendizaje no supervisado tiene la misma entrada que el supervisado (para este caso imágenes digitales de distintos colores).

Con los datos de entrada, el sistema aprende la mayor información posible que tenga a la mano, de hecho, el sistema trabaja de manera autónoma para reconocer el problema de clasificación y también la diferencia entre formas y colores. El sistema no supervisado está en capacidad de reconocer todos los objetos similares y agruparlos. Las etiquetas que se les da a estos objetos son diseñadas por la maquina en sí misma. Técnicamente, existe cierta cantidad ligadas a respuestas incorrectas, No obstante, también hay cierto grado de probabilidad de certeza. Aun así, de la misma manera que funcionamos los humanos, la fortaleza del ML recae en la habilidad para reconocer errores y aprender de ellos, y eventualmente realizar mejores estimaciones en las próximas ejecuciones(Maini, 2017; Mathworks, 2017; van Loon, 2018).

2.1.4.2.3. Aprendizaje reforzado

El aprendizaje reforzado es otra parte del ML que está ganando mucho reconocimiento acerca de cómo ayudar a las máquinas de como aprender de su progreso. Este concepto tiene un fundamento incluso a nivel psicológico.

El aprendizaje reforzado recae sobre el concepto de aprendizaje no supervisado, y da un amplio campo de control a los agentes de software y las máquinas para determinar cuál sería el comportamiento ideal dentro de un contexto dado. Este vínculo es formado para maximizar el rendimiento de la máquina de manera que ayude a su crecimiento. Una retroalimentación simple que informa a la máquina acerca de su progreso para ayudarla a aprender de su comportamiento.

El aprendizaje reforzado es complejo y está fundamentado en una gran cantidad de algoritmos. Como hecho de facto el aprendizaje reforzado un agente decide la mejor acción basado en el estado actual de los resultados.

El crecimiento del aprendizaje reforzado ha llevado a la producción de una amplia variedad de algoritmos que ayudan a las máquinas a aprender la salida de lo que se encuentran realizando. Existe una relación entre el aprendizaje reforzado y los conceptos de aprendizaje supervisado y no supervisado.

El aprendizaje supervisado en relación al aprendizaje reforzado, en el aprendizaje supervisado se tiene un supervisor externo el cual tiene el suficiente conocimiento del entorno y también comparte el aprendizaje con un supervisor para lograr una mejor comprensión y completar la tarea, desde que se han detectado algunos problemas, donde el agente puede realizar una gran cantidad de diferentes sub tareas por sí mismo para lograr el objetivo en general, la presencia de un supervisor es innecesaria e impráctica. Para entender esto podemos verlo desde la perspectiva del juego del ajedrez, un jugador puede realizar diez mil movimientos para lograr su último objetivo. Crear una base de conocimiento para este propósito puede ser una tarea muy complicada. Por lo tanto, es imperativo en que dichos tipos de tareas, el computador aprenda como manejar decisiones por sí mismo. Es por lo tanto más posible y pertinente para la máquina aprender de su propia experiencia. Una vez la máquina ha comenzado a aprender de su propia experiencia, cual puede ganar conocimiento de esta experiencia para implementar en futuras jugadas. En ambos tipos de aprendizaje existe cierto mapeo entre las capas de entrada y salida. Aunque en el concepto de aprendizaje reforzado, existe una función ejemplar obtenida por hallazgo propio, a diferencia del aprendizaje supervisado, el cual guía al sistema en el aprendizaje de la ruta correcta(Mathworks, 2017; Mitchell, 1997; van Loon, 2018).

En el caso del aprendizaje no supervisado, el reforzado básicamente tiene una estructura de mapeo que guía a la máquina a través de la entrada hasta la salida. Sin embargo, el aprendizaje no supervisado no tiene este tipo de características presentes en él. En el aprendizaje no supervisado la máquina se centra en la tarea subyacente de localizar patrones más que en el de mapear progresivamente el proceso hasta el objetivo final. Por ejemplo, si la tarea para una máquina es sugerir una actualización de noticias a un usuario, en un algoritmo de aprendizaje reforzado, buscará obtener una retroalimentación regular del usuario en cuestión, y a través de retroalimentación construyendo un grafo confiable de todos los artículos que le pudieran interesar a esa persona. Por el contrario, el algoritmo de aprendizaje no supervisado trataría de mirar otros artículos que la persona ya ha leído, similares a este, y trataría de sugerir algo que coincida con las preferencias del usuario(van Loon, 2018).

De manera gráfica, la clasificación del Aprendizaje Automático se muestra a continuación, donde se clasifican los distintos algoritmos para el aprendizaje supervisado y no supervisado (Granville, 2017).
Clasificación: Máquinas de Soporte Vectorial, Análisis Discriminante, Clasificador Bayesiano, Vecinos cercanos. Regresión: Regresión Lineal, SVR, GPR, Métodos de ensamblaje, Árboles de decisión,

Redes Neuronales. Clustering: K-means (medoids), C-Means Difusios, métodos jerárquicos, Redes Neuronales, Modelos Ocultos de Markov.



Ilustración 22 Tipos de aprendizaje en el aprendizaje automático. El aprendizaje puede ser supervisado, no supervisado, semisupervisado o, alternativamente, a través del aprendizaje reforzado. El aprendizaje supervisado se puede agrupar en tareas de clasificación o regresión dependiendo de si el verdadero objetivo es categórico o continuo. Las principales aplicaciones del aprendizaje no supervisado en los trastornos cerebrales incluyen la agrupación y la reducción de la dimensionalidad de los datos de entrada.(*Vieira et al., 2019*)

2.2. Trabajos Relacionados

2.2.1. Mindwanering: La mente divagante y el Default Mode Network

2.2.1.1. *Mente Divagante*

Recientes adelantos científicos, en el campo de la neurociencia, han podido demostrar la Dinámica alfa-theta (4 – 14 Hz) de EEG en la mente divagante en el contexto de la meditación centrada en la respiración, aplicando un enfoque de muestreo con practicantes novatos de meditación. Una parte importante de estas prácticas consiste en dirigir el enfoque de atención a un objeto específico (por ejemplo, la sensación de respirar) mientras 'se nota' y 'se deja pasar' los pensamientos autogenerados (es decir, episodios de divagación mental) (Brandmeyer & Delorme, 2018; Rodriguez-Larios & Alaerts, 2021). Se define por lo tanto desde la psicología que la mente divagante es **un fenómeno mental omnipresente que se define como un pensamiento autogenerado, irrelevante, desviando involuntariamente hacia temas no relacionados con la tarea que se esté desarrollando en curso** (Brandmeyer & Delorme, 2018; Jin C, 2021; Jin et al., 2019, 2020). La dinámica de la mente divagante sigue siendo esquiva porque es difícil rastrear cuando la mente de alguien se basa solo en el comportamiento. (Jin et al., 2019). Aun así, una considerable cantidad de estudios mediante análisis y procesamiento de señales EEG se ha llevado a cabo durante los últimos años para abordar este fenómeno desde la neurociencia, utilizando numerosas variables fisiológicas. (Beninger et al., 2021; Brandmeyer & Delorme, 2018; Y.-T. Chen et al., 2020a, 2020b; Christoff et al., 2009; Dong et al., 2021; Grandchamp et al., 2014; Groot et al., 2021; Hosseini & Guo, 2019; Jin C, 2021; Jin et al., 2019; Kawashima & Kumano, 2017; Rodriguez-Larios & Alaerts, 2021; Tasika et al., 2020)

Para hallar correlatos neurofisiológicos a nivel EEG de la mente divagando durante la práctica de la meditación. Se han adoptado dos paradigmas principales: muestreo de experiencias auto aprendidas (es decir, los participantes presionan un botón cada vez que se notan divagaciones) y muestreo de experiencias capturadas por validación (es decir, sondear a los participantes al azar intervalos de tiempo a lo largo de la meditación para informar si estaban divagando). (Rodriguez-Larios & Alaerts, 2021)

Otro factor que afecta la aparición de divagaciones mentales es el nivel de exigencia de la tarea. Los estudios de comportamiento han demostrado que el aumento de la demanda de tareas tiende a reducir la tasa de divagación mental, siempre que las demandas de la tarea no superen la capacidad de los participantes. Los estudios de electroencefalograma oscilatorio han demostrado que la vigilancia, la distracción mental y las demandas de tareas son sensibles a la actividad periódica en el rango alfa de 8-12 Hz. En la investigación de mente divagante, se ha demostrado que las oscilaciones alfa son un predictor constante de este estado mental.(Brandmeyer & Delorme, 2018; Jin et al., 2020; Rodriguez-Larios & Alaerts, 2021). Si bien el estudio (Jin et al., 2020) demuestra cómo los clasificadores de aprendizaje automático pueden ayudar a revelar similitudes y diferencias entre la distracción y otros procesos mentales al comparar sus marcadores neuronales característicos. Los resultados no mostraron ninguna diferencia significativa entre divagar y concentrarse en la tarea.(Jin et al., 2019). Sin embargo de manera más reciente se ha demostrado científicamente la existencia de una firma neuronal a nivel multimodal (EOG + EEG + fMRI) para la mente divagante.(Groot et al., 2021)

Desde una perspectiva traslacional, el estudio de (Rodríguez-Larios & Alaerts, 2021) indica que la actividad oscilatoria en el rango de frecuencia theta-alfa podría formar parámetros adecuados para desarrollar protocolos de EEG-neurofeedback destinados a facilitar la detección de la mente divagante durante la práctica de la meditación.

2.2.1.2. *Default Mode Network: Caracterización neurofisiológica y espectral*

En neurociencia, el Default Mode Network (DMN) o también conocida como red predeterminada o la red de modo predeterminado, es una **red cerebral** a gran escala compuesta principalmente por la corteza prefrontal medial, posterior, la corteza cingulada (pCC), las circunvoluciones frontales superior e inferior, los lóbulos temporales medial y lateral y la porción posterior del lóbulo parietal inferior (pIPL), muestran activaciones consistentes durante los episodios mentales captados por métodos de valoración por muestreo y auto informados. La red de modo predeterminado (DMN) **se refiere a las regiones del cerebro que están más activas durante un estado de reposo. Es más conocido por estar activo cuando una persona no está enfocada en el mundo exterior y el cerebro está en reposo despierto, como cuando sueña despierto y vaga la mente.** El Default Mode Network está orientado a la tendencia de pensamiento introspectivo, relacionado con los **pensamientos divagantes** como por ejemplo evocar pensamientos auto retrospectivos, del pasado o planificar eventos futuros, pensar en uno mismo o en los demás (American Academy of Neurology. et al., 2015; Berkovich-Ohana et al., 2014; Brandmeyer & Delorme, 2018; Buckner et al., 2008; A. C. N. Chen et al., 2008; Fomina et al., 2015; Garrison et al., 2015; Gennady G. Knyazev, Jaroslav Y. Slobodskoj-Plusnin, Andrey V. Bocharov, 2011; Jang et al., 2011a, 2011b; H. Kim, 2010, 2012; Knyazev et al., 2011; Neuner et al., 2014; Raichle, 2015; Scheeringa et al., 2008; Simon, 2015; Taylor, Daneault, Grant, Scavone, Breton, Roffe-vidal, et al., 2013; Taylor, Daneault, Grant, Scavone, Breton, Roffe-Vidal, et al., 2013).

Un metaanálisis de estudios de neuroimagen en estado de reposo ha revelado que las anomalías dentro de la DMN pueden contribuir a una interrupción en los procesos cognitivos, lo que lleva al deterioro o la aparición de trastornos cerebrales como autismo, TDAH, Alzheimer, esquizofrenia o ansiedad. (Buckner et al., 2008). En otros estudios se encuentra que la **mente divagante** se asocia con una reducción en el estado de alerta y una mayor actividad en el "Default Mode Network (DMN)", podría desempeñar un papel en la reducción en la capacidad de controlar la respuesta que se ha observado con la reducción del estado de alerta. (Jin et al., 2020). Sin embargo, se ha acumulado una gran cantidad de literatura durante la última década que sugiere que una supresión del procesamiento de DMN puede reflejar uno de los procesos neuronales centrales involucrados en la práctica extensa de meditación, y que la meditación conduce a un procesamiento de DMN relativamente reducido más allá del observado durante otros tipos de meditación o tareas cognitivas. (Brandmeyer & Delorme, 2018; Garrison et al., 2015). La meditación afecta la red del modo predeterminado al alterar la forma en que procesamos nuestros pensamientos mientras nuestras mentes divagan. El DMN está estrechamente relacionado con nuestros sentimientos y autopercepción. Como ya se demostró la meditación de atención plena es una forma eficaz de reducir la actividad de DMN. Puede ayudar a reenfocar el cerebro y evitar que la mente divague en un territorio estresante, como revivir eventos traumáticos del pasado o ansiedades sobre el futuro. (American Academy of Neurology. et al., 2015; Garrison et al., 2015; Jang et al., 2011a; Knyazev et al., 2011; Simon, 2015; Taylor, Daneault, Grant, Scavone, Breton, Roffe-Vidal, et al., 2013)

La interacción entre las respuestas neuronales temporalmente bien definidas y las redes funcionales localizadas espacialmente puede evaluarse mediante neuroimágenes multimodales. Aunque se han

realizado estudios combinando EEG con resonancia magnética en estado de reposo para determinar los correlatos electrofisiológicos de la DMN (Neuner et al., 2014; Bowman et al., 2017; Marino et al., 2019). Se recopilaron datos simultáneos de pupilometría y resonancia magnética funcional (fMRI-EEG) Como resultado, durante un experimento el DMN en comparación con una tarea centrada de atención, el DMN caracterizó por presentar una actividad más débil en la red de modo predeterminado pero una actividad elevada en su red anticorrelacionada, un acoplamiento funcional más fuerte entre estas redes, un aumento generalizado en la bandas de frecuencia de **alfa**, **theta**, delta, pero no beta, y un tamaño basal de la pupila más grande (Groot et al., 2021).

La caracterización electrofisiológica del DMN (A. C. N. Chen et al., 2008). Y sus mecanismos subyacentes (X. Chen et al., 2020) se pudo establecer a través de la covarianza espectral y correlaciones entre los campos de potencia en dos estados particulares de ojos cerrados y ojos abiertos realizando una captura de la señal EEG de 3 minutos con una resolución de 128 canales. Caracterizando mediante correlación cruzada los valores de poder espectral en las ondas EEG de baja frecuencia: (Delta y Theta), frecuencia media: Alpha y las ondas EEG de frecuencia alta: Beta 1 y 2.




Ilustración 23 La constelación de potencias de campo espectral medidas en un período de 3 minutos representa la distribución regional de las respectivas potencias de siete bandas de frecuencia en la topografía del cerebro, en el estado Ojos abiertos EO, VS Ojos Cerrados EC visto desde superior-anterior (sa) y superior-posterior (sp) perspectivas. El EEG DFN en reposo se compuso a partir de datos recopilados en 25 varones jóvenes universitarios sanos de Aalborg, Dinamarca, mientras el autor Chen dirigía el Laboratorio de Mapeo del Cerebro Humano. Los datos no se publicaron previamente. (A. C. N. Chen et al., 2008)

2.2.2. Meditación Mindfulness: Una terapia de relajación de la mente basado en conciencia plena asociada y un fenómeno neurológico en la electroencefalografía, En los últimos años, las versiones secularizadas de las prácticas contemplativas budistas se han vuelto cada vez más comunes en nuestra sociedad debido a sus supuestos beneficios para la salud (J. A. Brefczynski-Lewis et al., 2007a; Farb et al., 2007; Fingelkurts et al., 2015; Garrison et al., 2015; Goleman & Davidson, 2017; Gotink et al., 2016; Goyal et al., 2014; Irmischer et al., 2018; Jang et al., 2011b; JEN L. TEE & WAI Y. LEONG, 2018; Kaur & Singh, 2015; D.-K. Kim et al., 2013, 2014; Kirk & Montague, 2015; Lin & Li, 2017; J. Lutz et al., 2016a; Manuello et al., 2016; Rodriguez-Larios & Alaerts, 2021; Tang et al., 2015). Así mismo como abordar su estudio desde una perspectiva neurocientífica, la cual es detallada en “Altered Traits: Science Reveals How Meditation Changes Your Mind, Brain, and Body”(Goleman & Davidson, 2017) en donde los autores llevaron a cabo una revisión de la literatura de más de 6.000 estudios científicos sobre meditación y seleccionaron los 60 que creían que cumplían con los más altos estándares metodológicos.

El Mindfulness o conciencia plena es una forma de meditación con raíces en las prácticas espirituales budistas las cuales han sido empleadas en varias intervenciones de psicología clínica, incluyendo terapias de stress y comportamiento dialéctico. Este tipo de meditación **involucra una perspectiva más amplia de la meditación basada en la concentración en un solo objeto**, observando la experiencia del momento presente, que son, las sensaciones físicas, los pensamientos y los sentimientos (Anderson et al., 2007; J. a Brefczynski-Lewis et al., 2007; Ekman et al., 2005, 2014; Gotink et al., 2016; Goyal et al., 2014; Irmischer et al., 2018; Jang et al., 2011b; Kabat-Zinn, 2006; J. Lutz et al., 2016b; Tang et al., 2015).

La investigación fundamental y aplicada ha indagado acerca de los supuestos beneficios de la meditación y el entrenamiento mental. Principalmente, la neurociencia se ha centrado en los mecanismos del cerebro y correlación mental de la meditación. Particularmente, R. Davidson et al (Center for Investigating Healthy Minds, 2015) ha liderado una serie de extraordinarios, pero aun seminales estudios involucrando monjes budistas (Abercrombie et al., 1998; J. A. Brefczynski-Lewis et al., 2007b; Buckner et al., 2008; Craven W. Mark, n.d.; Ekman et al., 2005; Flook et al., 2013; A. Lutz et al., 2004) Por ejemplo, innovadores experimentos dirigidos por el monje budista francés Matthieu Ricard, obtuvieron recientemente importantes resultados: “durante la meditación, el cerebro de Ricard produce ondas de nivel gamma – las cuales se encuentran ligadas al conocimiento, la atención, el aprendizaje y la memoria – estos datos nunca habían sido antes reportados en la literatura” (A. Lutz et al., 2004) Intrínsecamente, por supuesto, la visión por computadora, el procesamiento de señales y aprendizaje automático, todas estas contribuyen a lograr estos descubrimientos en aspectos más técnicos. En vista de ello, en nuestros días, hay pocas dudas sobre los beneficios de la meditación Mindfulness en el tratamiento de los trastornos mentales (Anand et al., 2005b; Anderson et al., 2007; Brown & Ryan, n.d.; Carmody & Baer, 2008; Chiesa & Serretti, 2009) Esto particularmente aplica a depresión (Anand et al., 2005a; Baer, 2003) una condición psicológica que es tratada, de otra manera con diversos mecanismos invasivos como: Drogas antidepresivas (Pizzagalli, 2011), estimulación transcraneal (Mayberg et al., 2005), y más recientemente, Araujo et al (Aliño et al., 2015; McKenna, 2004; Shoemaker, 2014) han documentado en uso plantas psicodélicas como Ayahuasca.

Una pregunta sobresaliente en la literatura de la ciencia contemplativa se relaciona con el impacto directo de la experiencia de la meditación en el monitoreo de los estados internos y su respectiva correspondencia con la actividad neuronal. Respondiendo a la pregunta ¿En qué medida influye la

meditación en la conciencia, la duración y la frecuencia de la tendencia de la mente a divagar? Los resultados muestran que los practicantes de meditación expertos informan una mayor profundidad y frecuencia de meditación sostenida, mientras que los practicantes no expertos informan una mayor profundidad y frecuencia de episodios de divagación mental. Este es uno de los primeros índices conductuales directos de la experiencia en meditación y su impacto asociado en la frecuencia reducida de divagación mental (Brandmeyer & Delorme, 2018).

Los resultados de las activaciones de EEG muestran un aumento de la línea media frontal theta y ritmos alfa somatosensoriales durante la meditación en comparación con la mente divagando en practicantes expertos. Los ritmos theta de la línea media frontal y los ritmos alfa somatosensoriales se observan a menudo durante el funcionamiento ejecutivo, el control cognitivo y la monitorización activa de la información sensorial. Por tanto, el estudio de (Brandmeyer & Delorme, 2018) proporciona nueva evidencia adicional para apoyar la hipótesis de que el mantenimiento de las orientaciones de atención tanto internas como externas puede mantenerse mediante mecanismos neuronales similares y que estos mecanismos pueden ser modulados por el entrenamiento de la meditación. (Brandmeyer & Delorme, 2018) Cabe resaltar que dicho estudio se llevó a cabo en el Meditation Research Institute (MRI) en Rishikesh, India con meditadores experimentados. La importancia de este estudio radica en que proporcionan algunas de las primeras pruebas de que la **experiencia en meditación está asociada con una frecuencia atenuada de divagaciones mentales**. Comprobando que la experiencia en meditación se asoció con una profundidad significativamente mayor de absorción meditativa y un número significativamente reducido de pensamientos episodios errantes a lo largo del paradigma de muestreo de experiencias, además de mostrar la preponderancia de las ondas **theta y alfa** en la dinámica cerebral en eventos relacionados con mente divagante y meditación de la Ilustración 24 (Cavanagh & Frank, 2014, Cavanagh & Shackman, 2015) (Brandmeyer & Delorme, 2018; Lomas et al., 2015c) y con ello apoyar la hipótesis de que el mantenimiento de las orientaciones de enfoque y concentración tanto internas como externas puede mantenerse mediante mecanismos neuronales similares.

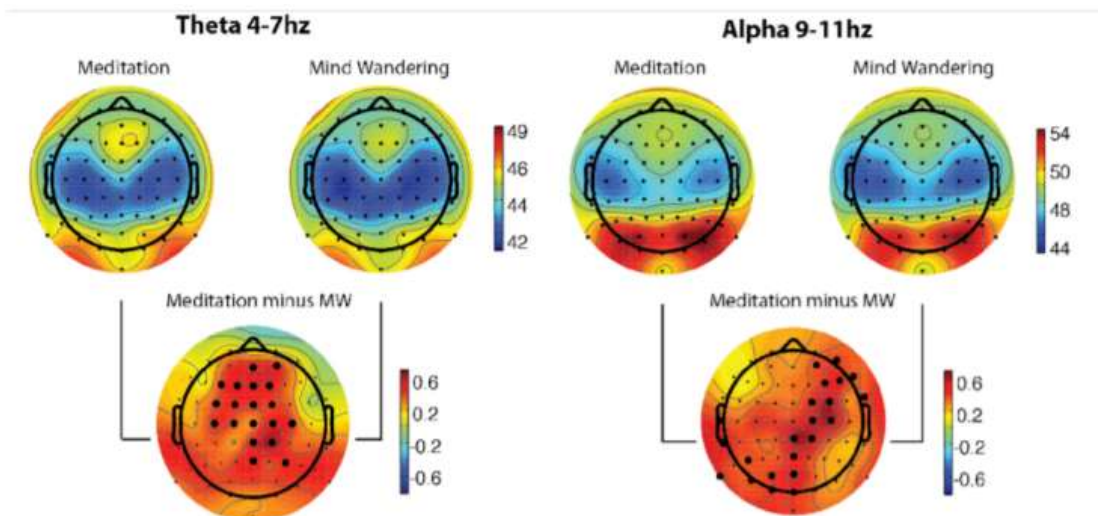


Ilustración 24 Gráficos de perturbación espectral relacionada con eventos (ERSP) y gráficos diferenciales de significancia en theta (4-7Hz) y alfa (9-11Hz) para practicantes de meditación expertos. La escala de potencia se expresa en $\mu V^2/ Hz$. Los puntos negros en las gráficas de diferencia indican electrodos significativos $p < 0,02$ después de la corrección de grupos para comparaciones múltiples. (Brandmeyer & Delorme, 2018)

Un conjunto de revisiones sistemáticas acerca de la neurofisiología de la atención plena en las oscilaciones del EEG y acerca de programas de meditación para mejorar el bienestar psicológico identificaron más de 284 artículos potencialmente relevantes en temas de relacionados con el Mindfulness (Fingelkurts et al., 2015; Goyal et al., 2014; Lomas et al., 2015a), en los cuales se examinó las diferencias de poder entre la atención plena y un estado de control. Concluyendo que la atención plena se asoció principalmente con los espectros de potencia **alfa y theta**, siendo este casi una “firma” de la conciencia plena. No se observaron patrones consistentes en términos de beta, delta y gamma. Alfa y theta elevados pueden significar un estado de alerta relajado.

De la misma manera que a nivel espectral se destacan ciertas características a nivel de regional dentro de la configuración internacional de electrodos 10/20. Particularmente los puntos en la sección frontal del cráneo F3 y F4 son seleccionados en base a estudios previos (Fingelkurts et al., 2015; JEN L. TEE & WAI Y. LEONG, 2018; Kaur & Singh, 2015; Oken et al., 2014), donde F3 y F4 fueron algunos de los puntos donde un aumento en las frecuencias de la banda theta durante la meditación fueron más observables.

Algunos de los patrones por los que el mindfulness se expresa electrofisiológicamente en el cerebro se ven reflejados por la reducción en la actividad del cortex medial prefrontal (MFPC) un componente central del DMN(Taylor, Daneault, Grant, Scavone, Breton, Roffe-Vidal, et al., 2013). Además, recientes estudios han demostrado que existen 4 áreas que juegan un rol esencial en la meditación mindfulness, el córtex sagital anterior, el córtex sagital posterior, el córtex insular y el tálamo como se puede ver en la Ilustración 25 (Manuello et al., 2016; Tang et al., 2015). Se ha demostrado que la práctica de la meditación conlleva a cambios en la conectividad funcional entre el núcleo del DMN reflejados posiblemente en el fortalecimiento de la mente consciente (Tang et al., 2015; Taylor, Daneault, Grant, Scavone, Breton, Roffe-Vidal, et al., 2013). Recientes experimentos abordan la meditación consciente y diversos artefactos para su detección y tipificación como (J. Lutz et al., 2016b).




Ilustración 25 Regiones del cerebro involucradas en meditación de atención plena. Vista esquemática de algunas de las zonas del cerebro involucradas en el control de la atención (la corteza cingulada anterior y el estriado) regulación de las emociones (regiones prefrontales múltiples, límbicas y el estriado) y autoconciencia (Insula, cortex prefrontal medio y corteza cingulada posterior y precuneus) (Tang et al., 2015)

2.2.3. Inteligencia Artificial y Aprendizaje automático en Interfaces Cerebro Computador Dadas las recientes revisiones sistemáticas basados en inteligencia artificial y algoritmos de clasificación en el uso de interfaces cerebro computador BCI (Cao, 2020; Lotte et al., 2018a). A continuación, se exponen algunos de los hallazgos realizados que permiten contextualizar el estado del arte de la investigación en el desarrollo de técnicas computacionales empleadas en BCI desde una perspectiva general:

El avance en la neurociencia y la informática promueve la capacidad del cerebro humano para comunicarse e interactuar con el medio ambiente, lo que convierte a la interfaz cerebro-computadora (BCI) en la principal investigación interdisciplinaria. Además, con el avance de la tecnología moderna en inteligencia artificial (IA), incluido el aprendizaje automático (ML) y los métodos de aprendizaje profundo (DL), existe un gran interés creciente en las BCI basadas en electroencefalogramas (EEG) para aplicaciones visuales, literales y literales relacionadas con la IA. y aplicaciones de movimiento. En este estudio de revisión, se investiga la literatura sobre las corrientes principales de IA para las aplicaciones de BCI basadas en EEG para llenar las lagunas en el campo interdisciplinario de BCI. Específicamente, primero se presentan brevemente las señales de EEG y sus principales aplicaciones en BCI. A continuación, se presentan las últimas tecnologías de inteligencia artificial, incluidos los modelos ML y DL, para monitorear y retroalimentar los estados cognitivos humanos. Por último, se presentan algunas aplicaciones de inteligencia artificial inspiradas en BCI, que incluyen la visión por computadora, el procesamiento del lenguaje natural y las aplicaciones de control robótico. Las direcciones de investigación futuras del BCI basado en EEG se destacan en línea con las tecnologías y aplicaciones de IA(Cao, 2020).

Los algoritmos de clasificación diseñados recientemente para BCI basados en EEG se pueden dividir en cuatro categorías principales: clasificadores adaptativos, clasificadores de matriz y tensor, aprendizaje por transferencia y aprendizaje profundo, además de algunos otros clasificadores diversos. Entre estos, se demostró que los clasificadores adaptativos son generalmente superiores a los estáticos, incluso con una adaptación no supervisada. El aprendizaje por transferencia también puede resultar útil, aunque los beneficios del aprendizaje por transferencia siguen siendo impredecibles. Los métodos basados en la geometría de Riemann han alcanzado un rendimiento de vanguardia en múltiples problemas de BCI y merecen ser explorados más a fondo, junto con los métodos basados en tensor. El análisis discriminante lineal de contracción y los bosques aleatorios también parecen particularmente útiles para entornos de muestras de entrenamiento pequeñas. Por otro lado, los métodos de aprendizaje profundo aún no han mostrado una mejora convincente con respecto a los métodos BCI de última generación. Un panorama general de esta clasificación es detallado en la Ilustración 26 (Lotte et al., 2018a).



Ilustración 26 Técnicas clásicas y modernas de clasificación de algoritmos para BCI (Lotte et al., 2018a)

2.2.4. Interfaces Cerebro Computador en la actualidad

Las interfaces cerebro-computadora (BCI) proporcionan un enlace de comunicación directo entre el cerebro y una computadora u otros dispositivos externos. Ofrecen un mayor grado de libertad ya sea fortaleciendo o sustituyendo la capacidad de trabajo periférica humana y tienen aplicaciones potenciales en varios campos como **rehabilitación, computación afectiva, robótica, juegos y neurociencia**. Los importantes esfuerzos de investigación a escala global han proporcionado plataformas comunes para la estandarización de la tecnología y ayudan a abordar dinámicas cerebrales altamente complejas y no lineales y desafíos relacionados con la extracción y clasificación de características. Las fluctuaciones psico-neurofisiológicas variantes en el tiempo y su impacto en las señales cerebrales imponen otro desafío para los investigadores de BCI para transformar la tecnología de experimentos de laboratorio a la vida diaria plug-and-play. Esta revisión resume los avances más recientes en el campo BCI durante las últimas décadas y destaca los desafíos críticos. (Saha et al., 2021). Las BCI han logrado un progreso inmenso y, según el informe de Grand View Research publicado en febrero de 2020, se espera que el tamaño del mercado global de interfaces cerebro-computadora alcance los **\$ 3.7 mil millones de dolares para 2027**. Lo que hace que esta área sea muy atractiva para todo tipo de iniciativas en todo el mundo.

2.2.5. Teoría y métodos de estimación espectral: Aplicación al análisis EEG

El objetivo de la estimación espectral, a veces llamado **estimación de densidad espectral**, es separar una forma de onda en diferentes oscilaciones de componentes basadas en **frecuencia**, al igual que un prisma separa la luz blanca en un arco iris de diferentes longitudes de onda o un ecualizador en un sistema de audio separa el sonido en diferentes bandas de frecuencia. En general, la estimación espectral toma cualquier señal en el dominio del tiempo. (trazas de forma de onda en función del tiempo) y la describe en el dominio de la frecuencia (potencia espectral en función de la frecuencia). La base teórica para la estimación espectral es el análisis de **Fourier** (Sörnmo & Laguna, 2005), que es un método que descompone una señal en el dominio del tiempo en una serie de ondas sinusoidales puras de diferentes longitudes de onda. Esto es particularmente útil en el análisis de datos de EEG, donde la señal representa la actividad combinada de múltiples redes de neuronas en todo el cerebro que oscilan a diferentes frecuencias (Prerau et al., 2017).

Una señal periódica estacionaria es aquella en la que la estructura de frecuencia no cambia con el tiempo. En **señales estacionarias**, es apropiado estimar un espectro de potencia, que representa la fuerza (potencia espectral) de la señal a diferentes frecuencias. La Ilustración 27 A, ARRIBA, ilustra cómo múltiples señales oscilatorias estacionarias se pueden sumar en una única forma de onda

agregada con una estructura temporal intrincada. Mientras las características de los componentes sinusoidales individuales son evidentes cuando se ven por separado, es considerablemente más difícil identificar el número de oscilaciones subyacentes y sus características al ver la forma de onda agregada. Sin embargo, al estimar el espectro de potencia de la señal, se hace evidente el número de oscilaciones, sus frecuencias y sus amplitudes (Prerau et al., 2017).

Si la estructura oscilatoria de una señal cambia con el tiempo, se dice que la señal es variable en el tiempo o **no estacionaria**. Si la intención es caracterizar cómo cambia la dinámica oscilatoria del EEG en el tiempo, no es apropiado estimar un único espectro de potencia para toda la señal. En cambio, se puede estimar un espectrograma para señales que varían en el tiempo. El **espectrograma** describe la potencia de la señal en función tanto de la **frecuencia** como del tiempo. A esto a veces se lo denomina mirar los datos en el dominio de tiempo-frecuencia. Para representar datos en el dominio de tiempo-frecuencia, podemos construir un espectrograma estimando el espectro de potencia en diferentes momentos utilizando una ventana móvil de datos. El tamaño de la ventana de datos se establece de manera que la estructura de los datos dentro de esa ventana sea aproximadamente estacionaria. Se visualiza un espectrograma con el eje x representando el tiempo, el eje y representando la frecuencia y la potencia espectral representada por el color (frío → cálido::bajo→alta potencia) en cada punto de frecuencia de tiempo. La Ilustración 27 B, ARRIBA, ilustra cómo se suman múltiples señales oscilatorias variables en el tiempo en una única forma de onda agregada. Al calcular el espectrograma (Ilustración 27 B, INFERIOR), La dinámica temporal de la estructura oscilatoria se hace evidente (Prerau et al., 2017).

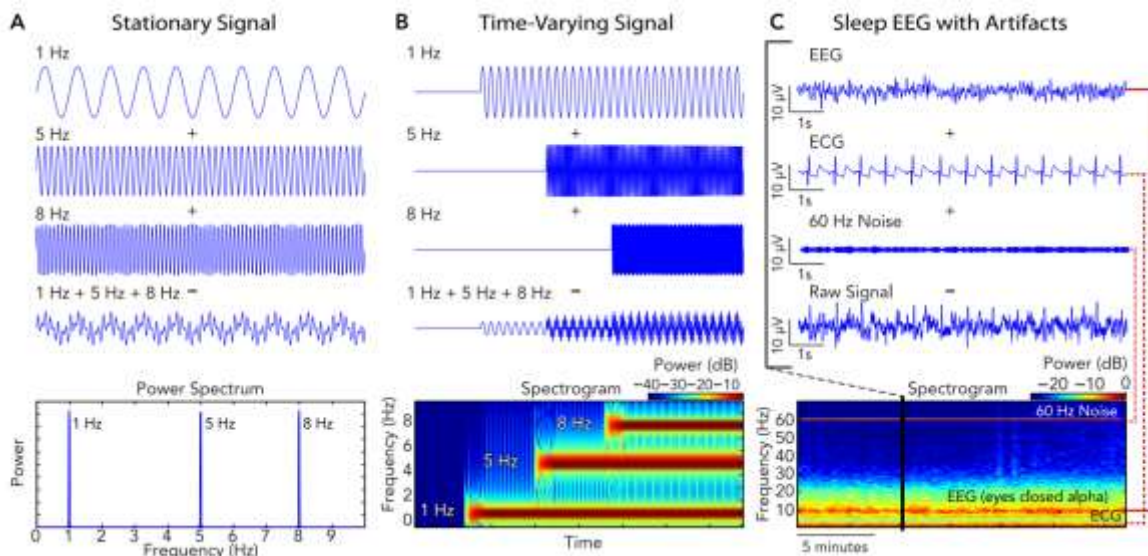



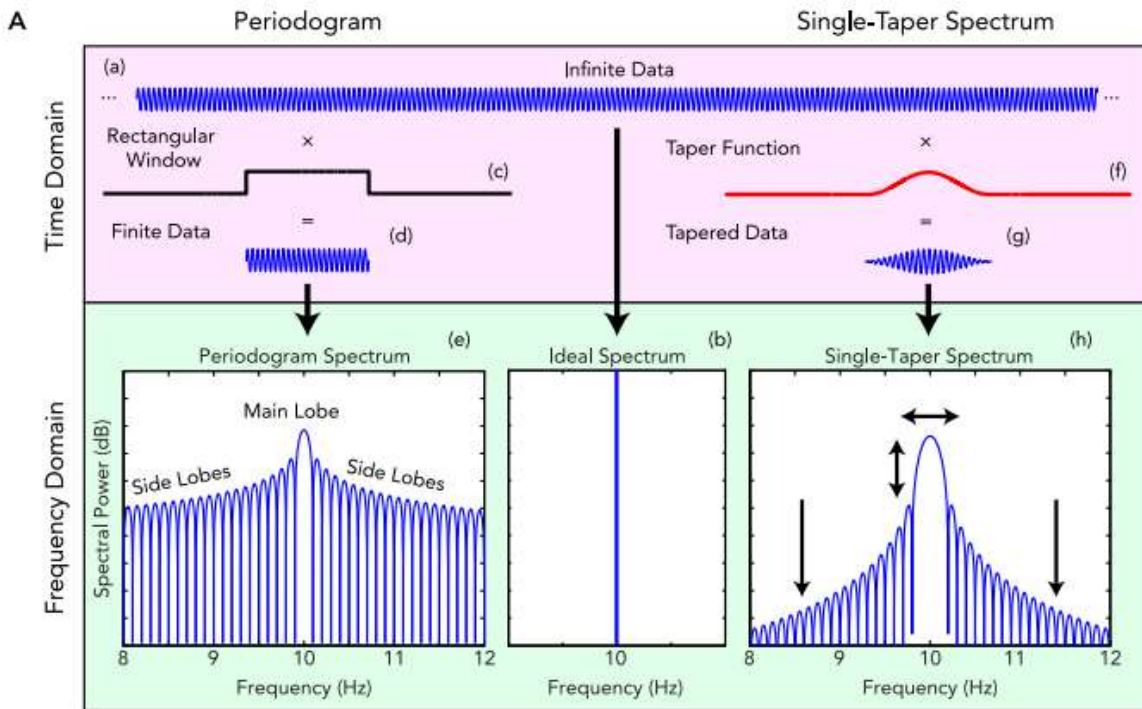
Ilustración 27 Una descripción general de la estimación espectral para señales estacionarias y variables en el tiempo La estimación espectral mediante el análisis de Fourier asume que cualquier señal puede representarse como la suma de múltiples ondas sinusoidales puras (A – C, arriba). Para señales con estructura periódica estacionaria (A), podemos calcular un único espectro de potencia (A, abajo), que representa la fuerza de la señal en diferentes frecuencias. Si la estructura oscilatoria de una señal varía en el tiempo (B), podemos calcular un espectrograma (B, abajo) que rastrea los cambios en el espectro de potencia a lo largo del tiempo. En la práctica, los datos de la forma de onda del EEG pueden estar "corruptos" por otras señales como ECG y ruido eléctrico de 60 Hz (C, arriba), y pueden descartarse como un artefacto. Sin embargo, dado que estas diferentes señales ocurren en diferentes frecuencias, el análisis espectral nos permite retener los datos, viendo cada señal de forma independiente en el dominio de tiempo-frecuencia (C, abajo). Tomado de (Prerau et al., 2017)

En el análisis de datos de EEG, el análisis espectral variable en el tiempo tiene numerosos beneficios. La Ilustración 27 C, ARRIBA, muestra un ejemplo de un trazo de EEG típico durante las primeras etapas del proceso de inicio del sueño. Si bien el objetivo es registrar solo datos de EEG, es común que otras señales biológicas o externas "corrompan" un registro clínico. En este ejemplo, la señal sin procesar contiene los datos de EEG deseados, pero también contiene actividad de ECG, así como ruido eléctrico de 60 Hz. Esto hace que la señal en el dominio del tiempo sea mucho más difícil de leer y, por lo tanto, es mucho más difícil caracterizar la actividad EEG subyacente. En consecuencia, este segmento de datos probablemente se consideraría corrupto y se descartaría, o se podrían aplicar técnicas de filtrado para "limpiar" los datos. Las técnicas simples de filtrado de paso de banda no son necesariamente una solución ideal, ya que pueden distorsionar los datos y pueden resultar inadecuadas para eliminar una señal compleja. Sin embargo, al utilizar el análisis espectral, no es necesario modificar los datos si los componentes de la forma de onda residen en frecuencias diferentes. En este caso, el espectrograma (Ilustración 27 C, INFERIOR) muestra el ruido eléctrico como una banda fuerte a 60 Hz, y el artefacto de ECG como una banda entre 1 y 2 Hz. La señal de EEG aparece como una banda en evolución a 10 Hz, que en este ejemplo representa la oscilación alfa con los ojos cerrados del sujeto que comienza a quedarse dormido (Prerau et al., 2017).

Basado en En (Prerau et al., 2017) las técnicas predominantes para la estimación espectral en aplicaciones como por ejemplo el EEG del sueño, producen estimaciones ruidosas e inexactas del espectro de potencia, dado que hay que superar la inercia asociada con los procedimientos establecidos y la relativa simplicidad de la puntuación clásica del sueño lo que dificulta la interpretación del espectrograma resultante. Allí, Se propone el uso de **estimación espectral múltitaper**, que es un método probado para mejorar en gran medida la claridad de las estimaciones espectrales sobre los métodos estándar. Para apreciar la motivación de la estimación espectral de múltitaper, es importante comprender los métodos utilizados en la estimación espectral, así como las consideraciones importantes que se deben tener en cuenta al realizar la estimación espectral en datos reales. Estas consideraciones se muestran en la Ilustración 28A usando un ejemplo de una senoide de 10 Hz.

La estimación espectral se basa en el análisis de **Fourier**, un área de las matemáticas que proporciona una base teórica para descomponer una señal en sus diferentes componentes de frecuencia. Este análisis teórico supone que las señales en el dominio del tiempo son infinitas, continuas, periódicas y pueden descomponerse en sinusoides puras. Así, dados datos puramente sinusoidales de longitud infinita (Ilustración 28Aa), podemos usar el análisis de Fourier para estimar un **espectro ideal**, que estará compuesto por picos perfectos (líneas verticales) en cada una de las frecuencias contenidas dentro de la señal en el dominio del tiempo (Ilustración 28Ab). Sin embargo, estos supuestos teóricos se rompen cuando analizamos datos reales, que son finitos, discretos, aperiódicos y variable en el tiempo. En consecuencia, el análisis espectral de datos reales puede producir estimaciones que difieren mucho del espectro ideal, produciendo resultados inexactos y potencialmente conduciendo a conclusiones falsas. Para obtener estimaciones espectrales más significativas para datos reales, Se utilizan diferentes estrategias para abordar los supuestos teóricos falsos, cada uno de los cuales viene con consideraciones especiales y compensaciones. Por ejemplo, los datos de EEG nunca son realmente estacionarios, por lo que es común analizar pequeños segmentos de tiempo de un experimento dentro de los cuales se supone que las propiedades de los datos no cambian. Si bien la estacionariedad mejora a medida que los segmentos de datos se vuelven más pequeños, nuestra capacidad para discernir oscilaciones en frecuencias poco espaciadas disminuye. La resolución espectral se define como la diferencia más pequeña en

frecuencias que podemos resolver. Por tanto, existe una compensación entre la longitud de la ventana de datos y la estacionariedad, por un lado, y la resolución espectral, por el otro. En las siguientes secciones, describiremos los métodos utilizados para la estimación espectral de datos de EEG y sus errores, seguidos de técnicas para mejorar la precisión espectral (sesgo y resolución) y la claridad (varianza) (Prerau et al., 2017).



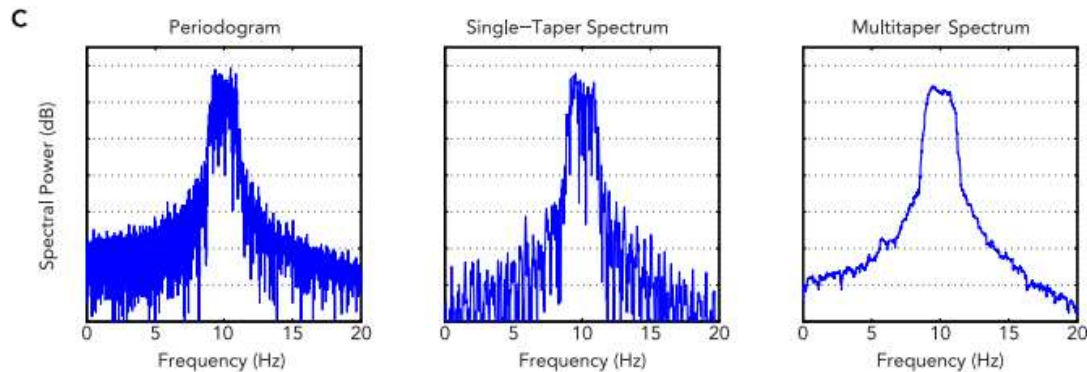


Ilustración 28 El análisis espectral de múltitaper reduce el sesgo y la varianza en la estimación espectral. A: una ilustración del sesgo del periodograma y los efectos de la disminución, utilizando una senoide de 10 Hz como ejemplo. En teoría, datos infinitos (a) produce un espectro ideal teórico con picos sin ancho en cada frecuencia (b). En la práctica, el periodograma de datos finitos (d) es un estimador espectral inexacto (sesgado) y ruidoso (variable) (e), con una estructura de múltiples picos causada por discontinuidades marcadas impuestas por datos finitos (c). La reducción gradual reduce el sesgo al tomar el producto de los datos y una función de "reducción gradual" (f) que suaviza las discontinuidades en los extremos de los datos (g). Al hacerlo, el estrechamiento reduce el sesgo al disminuir la potencia en los lóbulos laterales del espectro (h). B: un esquema de estimación espectral múltitaper, que funciona promediando múltiples espectros de single-taper que se calculan utilizando un conjunto especial de funciones ortogonales. C: una comparación de estimaciones espectrales para un pico espectral de EEG ruidoso simulado. El espectro de múltiples cónicos muestra un pico suave con un ruido muy reducido en comparación con el periodograma y estimaciones single-taper (ventana de Hanning) tomado de (Prerau et al., 2017)

2.2.5.1. El Periodograma: "Un Extremadamente Pobre Estimador espectral"

El método más simple y común utilizado para realizar la estimación espectral en los datos de EEG se llama Periodograma. En la práctica, el cálculo del Periodograma implica un algoritmo llamado transformada rápida de Fourier (**FFT**), que es una implementación eficiente de la transformada de Fourier para datos en tiempo discreto. Desafortunadamente, el **periodograma** tiene varias propiedades subóptimas que causan problemas importantes en la estimación espectral. De hecho, en su libro de texto *Spectral Analysis and Time Series*, Priestly llama al periodograma "una estimación extremadamente pobre (si no inútil) de la función de densidad espectral". Sin embargo, aunque rara vez aparece en cualquier aplicación de procesamiento de señales de última generación, el periodograma (a menudo denominado incorrectamente como "FFT") se utiliza ampliamente y sin reservas en la literatura sobre EEG (Prerau et al., 2017).

¿Qué hace que el periodograma sea un estimador tan pobre? Cuando calculamos el periodograma para una senoide pura en tiempo discreto, en lugar del pico único del espectro ideal, la estimación del periodograma se ve bastante diferente. La estimación espectral del periodograma resultante (Ilustración 28 A e) se compone de un gran pico redondeado en la frecuencia de oscilación, llamado lóbulo principal, flanqueado a ambos lados por una serie de picos más estrechos de potencia decreciente, llamados lóbulos laterales. Como veremos pronto, las discrepancias entre el periodograma y el espectro ideal puede causar problemas importantes para el análisis de datos de EEG y debe tratarse de manera efectiva para lograr resultados precisos (Prerau et al., 2017).

¿Por qué el espectro del periodograma difiere del espectro ideal? Una forma intuitiva de conceptualizar este fenómeno es pensar en cualquier serie de datos finitos (Ilustración 28 Ad) como el producto de datos infinitos (Ilustración 28 Aa) y una ventana rectangular o furgón (Ilustración 28Ac), con un valor de 1 para la duración de los datos y 0 en cualquier otro lugar. En consecuencia,

el periodograma de cualquier dato finito es la combinación (convolución) del espectro de datos ideal con el espectro de la ventana rectangular, que es una función de múltiples picos con un lóbulo principal y lóbulos laterales. El periodograma de una única senoide finita es el espectro de ventana rectangular centrado en la frecuencia de oscilación principal. Generalizado a todos los datos finitos, el periodograma será el espectro de ventana rectangular replicado en cada uno de los picos en el espectro de datos ideal, escalado por la amplitud de cada pico (Prerau et al., 2017).

¿Cómo afectan estas diferencias entre el periodograma y el espectro ideal al análisis de datos? La presencia de potencia del lóbulo lateral y principal significa que el periodograma de datos finitos es un estimador sesgado del espectro; es decir, el espectro de periodograma estimado para datos reales diferirá del espectrograma ideal (esperado), especialmente en los casos en los que la longitud de los datos es pequeña. Los lóbulos lateral y principal del periodograma permiten que el ruido a una frecuencia determinada se "filtre" en la estimación en otras frecuencias, distorsionando el contenido espectral verdadero de los datos. Esta fuga espectral, ya que se llama, reduce la precisión de la estimación y hace que sea más difícil distinguir claramente los picos en el espectro, especialmente en datos ruidosos como Electroencefalograma (Prerau et al., 2017).

Los lóbulos lateral y principal contribuyen al sesgo del periodograma de diferentes formas. Los lóbulos laterales introducen un sesgo de banda ancha, lo que significa que el ruido en un amplio rango o banda de frecuencias es incorporado en el presupuesto. En nuestro ejemplo de 10 Hz, el espectro ideal solo tiene potencia en la frecuencia de oscilación central. Por el contrario, el periodograma tiene lóbulos laterales que se extienden sobre todo frecuencias, indicando falsamente la presencia de potencia de banda ancha. La potencia, que debe concentrarse en una sola frecuencia, es redistribuida por el periodograma a las frecuencias donde lo hace. no pertenecer. Este sesgo de banda ancha puede ser particularmente problemático cuando los datos son ruidosos o tienen múltiples picos de frecuencia muy próximos. En tales casos, los lóbulos laterales de un periodograma actúan como transmisores, redistribuyendo el poder del ruido o las oscilaciones múltiples a frecuencias no relacionadas. Por lo tanto, sin tomar medidas para mejorar el sesgo, un periodograma de EEG puede corromperse fácilmente por ruido de fondo, artefactos y señales en frecuencias no relacionadas con las oscilaciones que se están estudiando (Prerau et al., 2017).

El lóbulo principal del periodograma es una fuente de sesgo de banda estrecha, ya que difumina todas las frecuencias dentro del pequeño rango de su ancho de banda. Esto significa que, si hay dos oscilaciones que son separados por una frecuencia menor que el ancho del lóbulo principal, se percibirán erróneamente como una oscilación. En el ejemplo de la senoide de 10 Hz, el pico ideal no tiene ancho, pero el lóbulo principal del periodograma es un pico con un ancho de banda de 0,2 Hz. Por tanto, la anchura del lóbulo principal determina la resolución espectral del espectro estimado, que es la diferencia más pequeña de frecuencias que se puede distinguir mediante la estimación espectral. La resolución espectral también determina la suavidad de la estimación a través de las frecuencias: una resolución espectral más gruesa corresponde a una estimación espectral más suave y viceversa. En la práctica, por lo tanto, es importante seleccionar una resolución espectral que sea menor que el ancho de banda de las oscilaciones que se van a analizar en los datos. Más adelante describiremos cómo definir explícitamente la resolución espectral en función de los supuestos subyacentes sobre las propiedades oscilatorias de los datos (Prerau et al., 2017).

2.2.5.2. *El espectrograma de Single taper: reducción del sesgo del estimador*

Dado el fuerte sesgo, el periodograma es un método de estimación espectral excepcionalmente inexacto. Afortunadamente, hay formas de reducir en gran medida el sesgo de periodograma. El método más común para mejorar el sesgo de periodograma es aplicar una función llamada función de ahusamiento o ventana a los datos finitos antes de realizar la estimación espectral (Prerau et al., 2017).

El resultado de este proceso puede denominarse espectro de **Single taper**. Recordamos que los lóbulos principal y lateral del periodograma para datos finitos surgen debido a los cambios bruscos en la ventana rectangular al principio y al final de los datos. Si deseamos reducir el sesgo causado por los lóbulos laterales, debemos suavizar la brusquedad de estas transiciones. Al tomar el producto de los datos brutos y una función de reducción gradual que tiene transiciones graduales entre 0 y 1 (Ilustración 28Af), los datos procesados (Ilustración 28Ag) se reducen gradualmente en ambos extremos (de ahí el nombre), disminuyendo la magnitud de las discontinuidades. Como resultado, la potencia en los lóbulos laterales del espectro de un solo cono (Ilustración 28 Ah) se reduce en gran medida en comparación con el periodograma (Ilustración 28Ae), y la diferencia de potencia entre el lóbulo principal y el más alto de los lóbulos laterales aumenta. Esto significa que habrá menos energía de las frecuencias circundantes que se filtrarán en la estimación espectral y, por lo tanto, la estimación estará menos sesgada (Prerau et al., 2017).

Otra forma de pensar en este proceso es que, al usar un tapers, la ventana rectangular afilada del periodograma se reemplaza efectivamente por una función más suave con mejores propiedades espectrales. En la práctica, se pueden utilizar muchos tipos diferentes de funciones como tapers en el cálculo del espectrograma de single taper. Los tapers típicos utilizados incluyen funciones de Hanning, Hamming, Blackman, Gaussian (a menudo denominadas transformadas de Gabor) y Welch, cada una de las cuales está diseñada para optimizar diferentes calidades del espectro para aplicaciones específicas. Cuando usamos una ventana de Hanning, un cono de uso común, en nuestro, Por ejemplo, las diferencias entre el periodograma y las estimaciones espectrales de single-taper son claramente visibles. Comparado con el Periodograma (Ilustración 28Ae), la potencia en los lóbulos laterales del espectro de multi-taper (Ilustración 28Ah) se reduce considerablemente, y la velocidad a la que la potencia disminuye en frecuencias alejadas del pico es mucho mayor. Además, aumenta la diferencia de potencia entre el lóbulo principal y los lóbulos laterales más altos. En consecuencia, el espectro single taper tiene contribuciones totales y relativas mucho más pequeñas de las frecuencias fuera de pico y, por lo tanto, habrá reducido significativamente la banda ancha. sesgo en comparación con el periodograma. Por lo tanto, cuando se utiliza el espectrograma de single taper con datos de EEG, podremos estimar con mayor precisión los picos oscilatorios que con un periodograma.(Prerau et al., 2017)

También en (Prerau et al., 2017) Se nota que el ancho del lóbulo principal es ligeramente mayor en el espectrograma de single-taper que, en el periodograma, lo que reduce la resolución espectral. En la práctica, existe una compensación entre el sesgo de banda ancha (lóbulo lateral) y de banda estrecha (lóbulo principal), que puede controlarse mediante la elección de la función de taper. En cualquier caso, siempre que la resolución espectral sea menor que el ancho de banda de las oscilaciones que se van a analizar, el aumento del ancho del lóbulo principal no debería causar problemas significativos en el análisis

2.2.5.3. *El espectro de Multitaper: reducción simultánea del sesgo y la varianza del estimador*

Otro problema importante en la estimación espectral es el concepto de la varianza de la estimación espectral, que caracteriza la incertidumbre en la estimación a través de frecuencias. El periodograma produce estimaciones con alta varianza en todas las frecuencias. Esto se ilustra en nuestro ejemplo, donde el espectro ideal (Ilustración 28Ab) tiene un solo pico vertical, mientras que el periodograma tiene visible y altamente lóbulos laterales variables (Ilustración 28Ae) alrededor de cada pico. Por tanto, el periodograma tiene una varianza mucho mayor que el espectrograma ideal. A medida que aumenta la longitud del conjunto de datos, la varianza del periodograma permanece constante. Por lo tanto, no importa cuántos datos se recopilen, la estimación del periodograma no mejorará. En consecuencia, llamamos al periodograma un estimador inconsistente del espectro (Prerau et al., 2017).

La varianza de la estimación espectral es una preocupación especialmente importante en el análisis de datos de EEG, que requiere una alta resolución temporal, lo que requiere el uso de ventanas de datos relativamente cortas. Además, aunque la reducción gradual reduce el sesgo, en realidad puede aumentar la varianza en conjuntos de datos cortos. Esto se debe a que la reducción gradual de los datos obliga a los puntos de tiempo cercanos a los extremos a converger a cero (Ilustración 28Ag), lo que reduce efectivamente la cantidad de datos disponibles para realizar la estimación y aumenta la varianza. Por lo tanto, los análisis de segmentos cortos de datos de EEG ruidosos son propensos a una gran variación, particularmente cuando utilizamos la puesta a punto para reducir el sesgo. Entonces, ¿cómo podemos producir una estimación espectral con un sesgo bajo y una varianza baja para segmentos cortos de datos? (Prerau et al., 2017)

En un mundo ideal, podríamos observar múltiples mediciones o ensayos independientes de la misma pequeña ventana de tiempo de actividad EEG. Al promediar todos los espectros de un solo cono de cada ensayo, podríamos cancelar el ruido de medición y reducir la varianza. Sin embargo, dado un solo segmento corto de datos, ¿qué se puede hacer para reducir la varianza? Para abordar este problema, podemos utilizar una técnica llamada **estimación espectral multitaper**, que fue desarrollada a principios de la década de 1980 por David Thomson y ha demostrado tener propiedades estadísticas superiores en comparación con las estimaciones espectrales de single-taper. El método de multitaper funciona promediando juntos múltiples espectros independientes estimados a partir de un solo segmento de datos. ¿Cómo es esto posible? La innovación del método multitaper es que, en lugar de usar una función de un solo cono para calcular el espectro, utiliza múltiples funciones de “afilamiento” (de ahí el nombre) para calcular espectros de single taper, que se promedian juntos. Estos tapers provienen de una clase particular de funciones llamadas secuencia esferoidal alargada discreta (DPSS). Los tapers DPSS son especiales porque no solo están optimizadas para reducir el sesgo, sino que también tienen una propiedad matemática especial llamada ortogonalidad, que les permite extraer estimaciones espectrales de single taper no correlacionadas a partir de los mismos datos. Debido a que estas estimaciones de single-taper no están correlacionadas entre sí, se pueden promediar juntas como si fueran ensayos independientes de la misma condición, produciendo un espectro con varianza reducida. Otra propiedad útil de las tapers DPSS es que facilitan particularmente la definición de la resolución de frecuencia espectral y la suavidad del espectro resultante (Prerau et al., 2017).

Por lo tanto, estimar el espectro de multitaper no es más complicado que tomar el promedio del espectro de varios de single-taper. La Ilustración 28 B muestra un diagrama esquemático para la

estimación espectral del múltitaper. Dado un segmento de datos, existen dos procedimientos para realizar el cálculo del espectro del multitaper: Estimación espectral multitaper y mediante selección de parámetros del multitaper (Prerau et al., 2017)

2.2.6. Referente neurocientífico de la mente divagante, la meditación y el DMN.

La introducción, diseño y prototipo de un sistema computacional que clasifique divagación mental durante actividad de atención plena o consciente durante ejercicios mentales relacionados con la meditación, es sustentado en la base del contexto neurocientífico por las siguientes afirmaciones que lo ratifican:

1. La mente divagante contribuye al aumento de algunos trastornos mentales: Mind-wandering o mente divagante es la experiencia de constantemente divagar con nuestros pensamientos, sin ninguna reacción consiente de hacerlo. Esto ocurre particularmente cuando no estamos enfocados en una tarea exigente o un objetivo específico. Mientras que no estar concentrado en el momento presente, puede ser útil en algunas ocasiones (P. Ej. Facilita la creatividad), cuando se presenta de manera excesiva puede traer consecuencias devastadoras, esto es principalmente la causa por que la mayoría del tiempo, nosotros entramos en modo de mente divagante en situaciones estresantes como inquietudes, reflexiones, preocupaciones, entre otras. De hecho, la evidencia científica ampliamente soporta el hecho de que la divagación mental esta correlacionado positivamente con la severidad de desórdenes mentales como depresión, ansiedad, trastornos bipolares entre otros. Más precisamente, uno de los principales trastornos de la depresión y la ansiedad está relacionado con un aumento de los pensamientos divagantes y no relacionados con las tareas que se están llevando a cabo.(Adomavicius & Tuzhilin, 2005; Anand et al., 2005b; Brown & Ryan, n.d.; Carmody & Baer, 2008; Chiesa & Serretti, 2009; Goldin & Gross, 2010; Koszycki et al., 2010; Shneiderman & Plaisant, 2009; Smallwood et al., 2009)

2. La mente divagante surge de la actividad en estado mental de red por defecto o en ingles Default Mode Network DMN: Recientemente, los neurocientíficos han encontrado las bases neuronales de la mente divagante. Existe una red de regiones del cerebro (DMN) que oscila sincrónicamente y de manera más activa cuando la mente se encuentra divagando respecto a cuándo se encuentra en una tarea demandante de atención. De hecho, estudios de imágenes de resonancia magnética funcional (fMRI) muestran que durante el descanso consiente (mindfulness), esta red muestra la más alta activación de coherencia neuronal. Del mismo modo, cuando se les pide a los participantes de un experimento que se concentren en una tarea específica, se hace con el fin de ubicar la zona para la desactivación de tareas inducidas. En otras palabras, engañar al DMN para producir pensamientos espontáneos durante el Mind-Wanderig. (Anand et al., 2005b; Austin, 2006; Buckner et al., 2008; Christoff et al., 2009; Farb et al., 2007; Jang et al., 2011a)

3. La meditación Mindfulness regula la actividad del DMN: Mindfulness es una forma de meditación elaborada para desarrollar habilidades para mejoramiento de la atención siendo totalmente consciente de las experiencias exteriores e interiores. No de modo sorprendente, estudios sugieren que los mecanismos neuronales basados en entrenamiento a través de Mindfulness se encuentran asociadas con actividades diferenciales del DMN. Específicamente, imágenes de resonancia magnética funcional (fMRI) revelaron que después de un curso de 40 días, la reducción de la actividad en DMN en meditadores novatos fue aparente. Estar conscientes de la respiración es tal vez una de las técnicas más populares del Mindfulness. Los aprendices deben estar vigilantes de su respiración de manera atenta e ininterrumpida, hasta que comience a pasar de manera natural (Por

el mayor tiempo posible). Esta tarea aparentemente simple puede convertirse en extremadamente difícil para quienes no son familiares con el método, por no mencionar los sujetos con trastornos mentales como la depresión. No importa que tanto intenten, sus mentes constantemente divagan sin conciencia de hacerlo, en lugar de seguir respirando. (a et al., 2011; Anderson et al., 2007; Austin, 2006; Baer, 2003; Bishop et al., 2004; Jang et al., 2011a)

3. CAPITULO 3. METODOLOGÍA: DESCRIPCIÓN DETALLADA DEL PROCESO

3.1. Materiales y Métodos

Con el objetivo **de diseñar un modelo e implementar un prototipo computacional, para la detección de estado de mente divagante, que contribuya en el aprendizaje de la meditación.** Se proponen llevar a cabo metodológicamente los objetivos específicos presentados en este capítulo.

Esta metodología basada en investigación cuantitativa se desarrolla bajo la siguiente hipótesis: Lograr capacidad discriminativa para la detección de mente divagante utilizando técnicas de procesamiento de señales EEG y Aprendizaje Automático que pueda generar un desempeño significativo en la clasificación de mente divagante **MW** Y concentración en la respiración **BF**.

La modalidad bajo la cual se realizará el procesamiento de señal EEG será **offline**. Soportado además en que las técnicas de remoción de artefactos han mostrado su desempeño al ser empleadas bajo dicho paradigma. Siendo la inspección visual asistida por un humano una de las técnicas que garantiza mayor confiabilidad. **Con este proyecto se busca disponer de características lo suficientemente robustas para lograr que un clasificador no disminuya su desempeño ante la presencia de artefactos.** En la remoción de artefactos con parpadeo se utilizan técnicas como ICA y la señal EOG, esta técnica se descarta, ya que no se dispone en este proyecto de una metodología automática que caracterice la presencia de artefactos de esta manera. Además, la técnica presentada favorece la proyección de este análisis a una escala online. En resumen, se busca discriminar la mente divagante de sus siglas en ingles MW (Mind Wandering) de atención basada en la concentración sobre la respiración BF (de las siglas en ingles Breath Focus), con presencia de artefactos, donde si bien es conocido la presencia de artefactos, estos no estarán presente en todas las épocas, pero es muy probable que se encuentre presente a lo largo de las mismas. Con esto se pretende validar que a pesar de la presencia de artefactos lograremos que la desviación inducida por este fenómeno no sea significativa.

Se debe tener en cuenta que la señal EEG dispone de ciertas restricciones:

- Es un sistema No Determinístico.
- Estocástico, ya que la señales varían en el tiempo y son **no estacionarias**.
- No Lineal.
- Baja relación señal – ruido.
- Presencia de artefactos (Principalmente EOG).

Un diagrama de flujo de trabajo utilizado se presenta a continuación Ilustración 29:

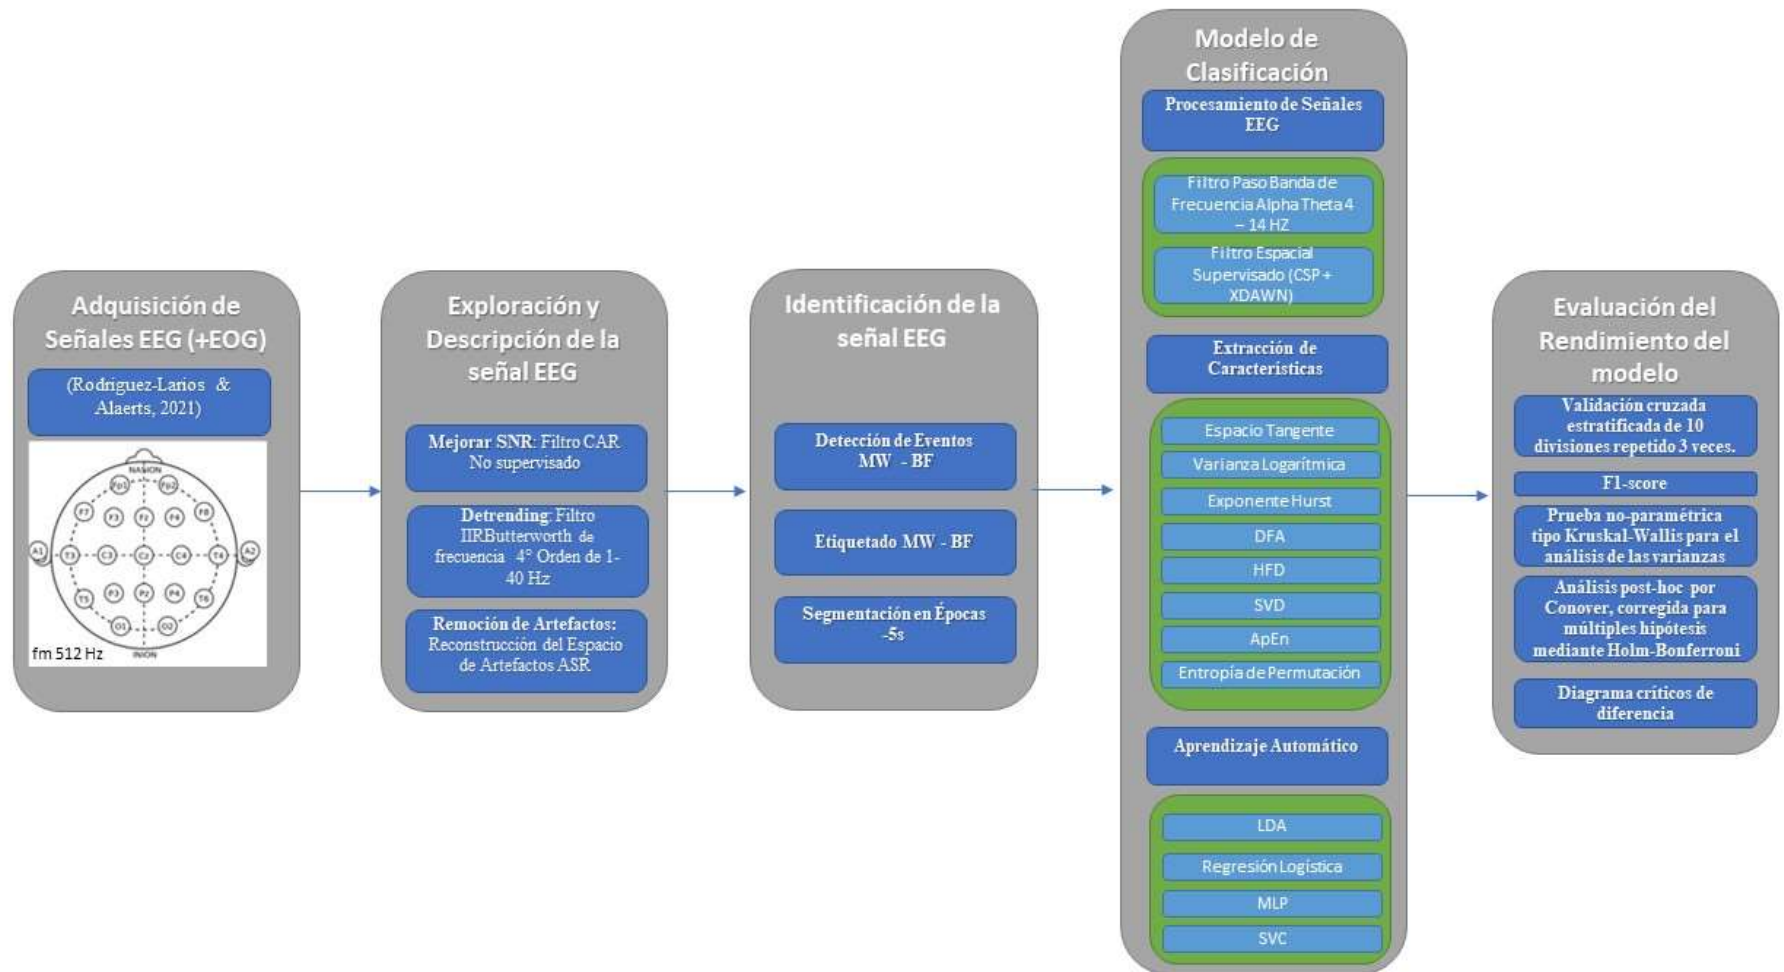


Ilustración 29 Descripción detallada del flujo de trabajo de procesamiento y clasificación de señales EEG para mente divagante.

3.1.1. Establecer los datos provenientes de análisis neuronales con el fin de proyectar experimentos para la detección del Default Mode Network (DMN)

3.1.1.1. *Descripción de los datos obtenidos*

La información acerca de la señal EEG, proviene de una fuente no estructura (Rodriguez-Larios & Alaerts, 2021), basada en la siguiente descripción:

- Archivos de texto de datos de EEG los cuales contienen EEG sin procesar (una columna por canal) e información de activación (columna 'Evento'). La frecuencia de muestreo es de 512 Hz.
- Archivos de texto de datos EOG que contiene archivos de texto EOG sin procesar, incluidos los canales HEOG y VEOG. La frecuencia de muestreo es de 2048 Hz. Estos archivos no serán considerados dentro de la eliminación de artefactos o la clasificación.

La referencia de los eventos que se activan durante el procedimiento de captura de la neuro señal son:

100 = sonido de campana

101 = Respuesta de enfoque en la respiración

102 = Respuesta de la mente divagante

Los dos eventos posteriores indican el nivel de confianza (1 a 7) y la excitación (1 a 5) que fueron calificados por cada uno de los participantes. Los detalles del protocolo de captura se encuentran detallados en 3.2.1

3.1.1.2. *Librerías utilizadas en el análisis de datos*

Se usan librerías de Python de análisis matemático y estadístico en como numpy (Harris et al., 2020), SciPy (The SciPy community, 2021), de manipulación y análisis de datos como pandas (McKinney, 2010). Así como librerías para el análisis y procesamiento de señales EEG como pyEDFlib, PyEDFlib es un conjunto de herramientas de código abierto para leer / escribir archivos EDF / EDF + / BDF. MNE (Gramfort, 2013), pyriemann (Barachant et al., 2012, 2013) y meegkit (Barascud Nicolas, 2021).

3.1.1.3. *Funciones Implementadas*

Las funciones implementadas para el procesamiento de datos EEG, van desde la carga de artefactos con datos EOG, a los de procesamiento de señales EEG como la implementación de filtro de referencia promedio común (CAR), implementación de filtro Butterworth de frecuencia, remoción de artefactos con el algoritmo reconstrucción del subespacio de artefactos (ASR) aplicando ventanas deslizantes no superpuestas, filtrado pasa banda en frecuencia y algoritmos con aplicación de transformes basados en Scikit-learn (Pedregosa et al., 2011) para extracción de características se utilizan técnicas de espacio tangente, varianza logarítmica y las heredadas de PyEEG (Bao et al., 2011). Pasando por algoritmos de validación estadística como los presentados en (Combrisson & Jerbi, 2015).

3.1.1.4. *Acceso al repositorio de datos con las señales EEG*

Los datos se encuentran disponibles mediante el repositorio de datos OSF del Center For Open Science (Center for Open Science, 2021) . El centro para la ciencia abierta se encuentra avalado por más de 200 benefactores de las principales universidades e instituciones de investigación del mundo

y su misión es aumentar la apertura, integridad y reproducibilidad de las investigaciones científicas. De manera conjunta con la disponibilidad de set de datos utilizados en este análisis, se encuentran el código en MATLAB utilizado en el procesamiento y clasificación de las señales EEG/EOG, así como los demás elementos bases asociados al protocolo y los resultados de la investigación según (Rodríguez-Larios & Alaerts, 2021).

3.1.1.5. *Información del procedimiento de captura de la señal EEG*

Veintiocho sujetos participaron en este estudio. El Sistema utilizado para la captura de datos EEG es un Nexus-32 (version 2015a, Mind Media, The Netherlands) con un casco de 22 electrodos, posicionado conforme al sistema de internacional 10-20. Los canales utilizados fueron: 'FP1', 'FP2', 'F7', 'F3', 'Fz', 'F4', 'F8', 'T3', 'C3', 'Cz', 'C4', 'T4', 'T5', 'P3', 'PZ', 'P4', 'T6', 'O1', 'O2', 'A1', 'A2'. La señal de EEG se amplificó utilizando un amplificador unipolar con una frecuencia de muestreo de 512 Hz todo lo anterior basado en (Rodríguez-Larios & Alaerts, 2021)..

3.1.2. Evaluar las técnicas de procesamiento de neuroseñales EGG para la detección de DMN a través de dispositivos BCI

3.1.2.1. *Importación de los Datos*

Los datos son leídos como un tipo DataFrame de pandas, para cada uno de los sets de datos disponibles. La matriz obtenida cuenta con unas dimensiones de 1275906 filas aproximadamente por 22 columnas.

3.1.2.2. *Recopilación de Datos “Data Munging”*

A veces confundido con la manipulación de datos, el término acuñado del inglés “Munging” es el proceso inicial de refinar los datos sin procesar en contenido o formatos más adecuados para el consumo de los sistemas y usuarios posteriores. El término 'Mung' se acuñó a finales de los 60 como un término un tanto despectivo para las acciones y transformaciones que degradan progresivamente un conjunto de datos.

En esta fase podemos observar el tipo de datos numéricos asociado a las magnitudes de cada uno de los canales, además de la información de la cabecera con las respuestas a las preguntas de los potenciales evocados de mente divagante MW o concentración en la respiración BF.

3.1.2.3. *Procesamiento de neuroseñales sobre los datos crudos*

3.1.2.3.1. Filtro Butterworth de frecuencia

Basado en (Rodríguez-Larios & Alaerts, 2021) los datos se filtraron mediante filtro Butterworth de 4° orden pasa banda con frecuencias de corte entre 1 y 40 Hz. Mediante el cual se devuelven los coeficientes del filtro. El filtro esta implementado sobre el paquete de procesamiento de señales de SciPy (The SciPy community, 2021). Que es una colección de algoritmos matemáticos y funciones de conveniencia creadas en la extensión NumPy de Python.

3.1.2.3.2. Remoción de artefactos: Reconstrucción del subespacio de artefactos (ASR)

El ruido abrupto en los datos se eliminó utilizando el Método de reconstrucción del subespacio de artefactos ASR. La técnica de Reconstrucción del subespacio de artefactos es tomada como referencia y adaptada de (Rodríguez-Larios & Alaerts, 2021) Esta técnica toma como referencia una ventana basada en el estado de reposo sobre la muestra EEG. Se aplicará análisis estadístico del rendimiento con el fin de evaluar si esta técnica incide favorablemente en el desempeño.

La reconstrucción del subespacio de artefactos (ASR) es un método automático, en línea y basado en componentes que puede eliminar de manera eficaz los artefactos transitorios o de gran amplitud que contaminan los datos electroencefalográficos (EEG). ASR aprende las propiedades estadísticas de los datos de calibración limpios y compara estas estadísticas durante el procesamiento con las estadísticas de los nuevos datos, que pueden contener artefactos. Se recomienda que los datos de calibración tengan una duración de al menos 1 min y se registren del participante respectivo durante el descanso en condiciones de registro comparables a las del procesamiento posterior. (Blum et al., 2019; Chang et al., 2020; Mullen et al., 2015).

El algoritmo ASR consta de dos partes, la calibración y el procesamiento. Durante la calibración, los datos se filtran, luego se calcula una matriz de covarianza robusta U , $U \in \mathbb{R}^{c \times c}$, siendo c el número de canales, utilizando la mediana L1 de las matrices de covarianza de muestra subsiguientes del segmento de datos entrantes. La mediana geométrica, o mediana L1 se define como:

$$U = \operatorname{argmin}_U \sum_{i=1}^n \|X_i X_i^T - U\|_2$$

Ecuación 34

Donde argmin minimiza la distancia euclidiana de X a U y n denota la cantidad de matrices de covarianza calculadas hasta ahora durante la calibración. Las matrices de covarianza de muestra única se calculan como:

$$\operatorname{Cov}(s) = X(s) X(s)^T, \operatorname{Cov}(s) \in \mathbb{R}^{c \times c}$$

Ecuación 35

siendo c el número de canal, $X(s) \in \mathbb{R}^{t \times c}$ el segmento de datos, s que consta de canales c y t muestras. Luego se usa U para calcular la matriz de mezcla $M \in \mathbb{R}^{c \times c}$ tal que $MM^T = U$. Mientras se aprende el modelo estadístico, esta matriz de mezcla M se descompone usando PCA para obtener $V \in \mathbb{R}^{1 \times c}$ y $D \in \mathbb{R}^{1 \times c}$, los vectores y valores propios de la matriz de mezcla. Al final de la fase de calibración, los datos se proyectan en el espacio de componentes donde se calculan las propiedades estadísticas de cada componente. Estas estadísticas se utilizan para determinar un operador de umbral $T = \mu + k \times \sigma$, $T \in \mathbb{R}^{c \times c}$, siendo μ , σ la media y la desviación estándar de los componentes y k un parámetro de ajuste, evaluado en (Chang et al., 2020). La matriz de umbral T define los límites de los datos normales durante el procesamiento. Durante el procesamiento, la matriz de covarianza actual $\operatorname{Cov}(s)$ se promedia con el registro del segmento de datos anterior que se estaba procesando. Esas matrices se suavizan temporalmente, $U(s) = f(\operatorname{cov}(s), U(s-1))$ donde $U(s) \in \mathbb{R}^{c \times c}$ depende del parámetro de tamaño de paso elegido para el segmento de datos s y f es una función media euclidiana ponderada. La cantidad de matrices de covarianza en U que se descomponen en sucesión depende del parámetro de longitud de la ventana y la cantidad de muestras actualmente en el método: rango = frecuencia de muestreo * longitud de la ventana (500 ms por defecto). Rango define el tamaño de U : $C \times C \times \text{rango}$, el intervalo de actualización utilizado para la descomposición se define por el rango sobre el tamaño del intervalo que se traduce en varios

miles de iteraciones de descomposición y reconstrucción para cada segmento de datos en el método ASR. Durante este ciclo de procesamiento principal, U se indexa en trozos de tamaño escalonado, esas $U(s) \in \mathbb{R}^{c \times c}$ se utilizan para detectar y reconstruir artefactos. En el espacio de componentes, los datos se reconstruyen utilizando la matriz de mezcla M de la calibración y una parte de los vectores propios V_{clean} of $U(s)$, es decir, los de los componentes limpios determinados por el operador de umbral $T: X_{\text{clean}} = M(V_{\text{clean}}^T M)^+ V^T X$. Como resultado, el artefacto se elimina de los datos. (Blum et al., 2019).

La implementación de ASR utilizada en esta investigación se encuentra basada en la clase *meegkit.asr.ASR* de la librería MEEGKit, la cual comprende un conjunto de herramientas de eliminación de ruido para el procesamiento de señales M/EEG en Python 3.7+. (Barascud Nicolas, 2021), utilizando Calibración para el método de reconstrucción del subespacio de artefactos. La entrada a estos datos es una serie de tiempo multicanal de datos de calibración. En usos típicos, los datos de calibración son datos limpios de datos de EEG en reposo si la fracción del contenido de artefactos está por debajo del punto de ruptura de las estadísticas sólidas utilizadas para la estimación (50% teórico, ~ 30% práctico). Si los datos tienen una proporción de más del 30-50% de artefactos, las ventanas de tiempo incorrecto deben eliminarse de antemano. Estos datos se utilizan para estimar los umbrales que utiliza la función de procesamiento de ASR para identificar y eliminar los componentes del artefacto.

Los datos de calibración deben haberse registrado para el mismo diseño de casco o gorro del que se registrarán los datos para la limpieza, e idealmente deben ser de la misma sesión y el mismo tema, pero es posible reutilizar los datos de calibración de una sesión anterior y montaje en el grado en que el límite se coloca en la misma ubicación (donde la pérdida de precisión es más o menos proporcional al desajuste en la colocación del límite). Los datos de calibración deberían haber sido filtrados en paso alto (por ejemplo, a 0.5Hz o 1Hz usando un filtro Butterworth IIR), y estar razonablemente limpios por lo menos 30 segundos (este método se usa típicamente con 1 minuto o más). El método utilizado para este análisis se encuentra basado en geometría euclidiana, ya que, en su implementación original, ASR descompone matrices de covarianza de los datos de EEG para la detección de artefactos usando geometría euclidiana tradicional. (Blum et al., 2019)

3.1.2.3.3. Filtro de referencia promedio común (CAR)

CAR es un filtro espacial que podría considerarse como la obtención del valor promedio y la sustracción del valor promedio de la actividad común de EEG, el cual deja solo la actividad inactiva de cada EEG individual en un electrodo específico (Ilustración 30). El potencial de cada electrodo después del filtro podría calcularse como en la Ecuación 36, donde $x_i^{CAR}(t)$ es la salida filtrada del electrodo i -ésimo, $x_j(t)$ es el potencial entre el j -ésimo electrodo y la referencia, C es el número total de todos los electrodos en el cuero cabelludo. (Yu et al., 2014).

$$x_i^{CAR}(t) = x_i(t) - \frac{1}{C} \sum_{j=1}^C x_j(t)$$

Ecuación 36




Ilustración 30 Diagrama de Filtro CAR

3.1.2.4. Exploración de los datos de la señal EEG

Las estadísticas generales de los datos fueron obtenidas mediante perfilamiento con pandas (McKinney, 2010), elaborando un reporte de los datos que vienen dadas por 21 variables numéricas correspondientes al valor de la amplitud por cada uno los canales del aparato EEG y una variable categórica donde se encuentra depositada la respuesta a los ERP para cada evento de toque de campana. Adicionalmente se obtuvo un reporte por canal con información promedio, valor mínimo y máximo.

Tabla 2 Métricas generales de los datos EEG obtenidos mediante perfilamiento

Numero de Variables	22
Numero de Observaciones por muestra	1275904
Tamaño total de memoria por muestra	223.9 MiB
Tamaño promedio en memoria por muestra	184.0 B

Se realizo un gráfico de cajas por canal para cada uno de los sujetos de prueba con el fin de observar la distribución de la magnitud de la amplitud de las señales por cada uno de los canales, como se muestra en la Ilustración 31




Ilustración 31 Diagrama de grafico de cajas mostrando la distribución de las amplitudes para cada uno de los canales del EEG, caso de estudio de muestro para individuo número 3 del estudio de (Rodríguez-Larios & Alaerts, 2021).

3.1.2.4.1. ¿Como evolucionan las señales EEG en el tiempo?

Para responder en esta pregunta en relación con el experimento realizado en (Rodriguez-Larios & Alaerts, 2021) se realiza un gráfico mostrando el comportamiento de la amplitud de señal en función del tiempo mientras se realiza el procedimiento de registro EEG, lo que corrobora gráficamente el protocolo de captura donde se puede observar en la línea vertical de color negro el evento de activar el sonido de la campana, seguidamente la respuesta al estado mental relacionada para el caso de mente divagante MW línea vertical color rosa y para el de estado mental con concentración en la respiración color amarillo.

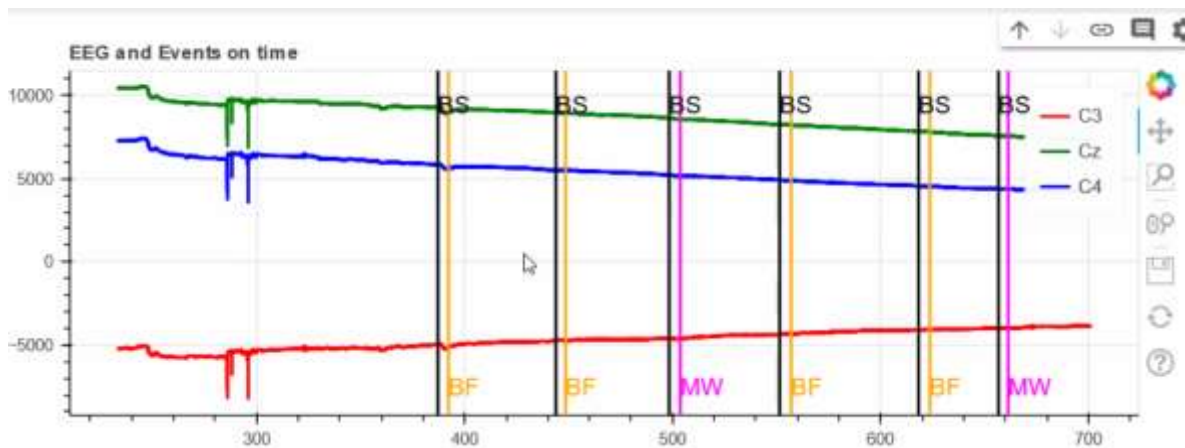


Ilustración 32 Grafico del comportamiento de la amplitud en función del tiempo para los canales C3, Cz y C4 del EEG durante el procedimiento de registro de señales EEG en el experimento de (Rodriguez-Larios & Alaerts, 2021).

3.1.2.5. Segmentación de la señal EEG y etiquetado de las épocas

Se implementó un algoritmo basado en búsqueda lineal y máquina de estados, a partir del evento de sonido de campana **BS** en el cual se almacenan junto con la respuesta al intervalo de confianza de 1 a 7 y al grado de excitación de 1 a 5, el índice de tiempo sobre el cual fue realizado la captura del evento de BS. Con estos datos se puede obtener una lista con la referencia completa para cada evento de BS a lo largo de la grabación del EEG. Con base a esta segmentación la referencia a los eventos de BS posteriormente es almacenada en formato intercambiable para almacenamiento de datos electrofisiológicos EDF, con el fin de validar el tratamiento de la señal, la secuencia de electroencefalografía es visualizada mediante un software especializado para graficar señales EEG como muestra la Ilustración 33. Por último, se aplica una segmentación a los 5 segundos previos al sonido de la campana BS con el fin de obtener la época que corresponde a la activación del estado mental de divagación mental MW o concentración en la respiración BF como lo describe (Rodriguez-Larios & Alaerts, 2021).

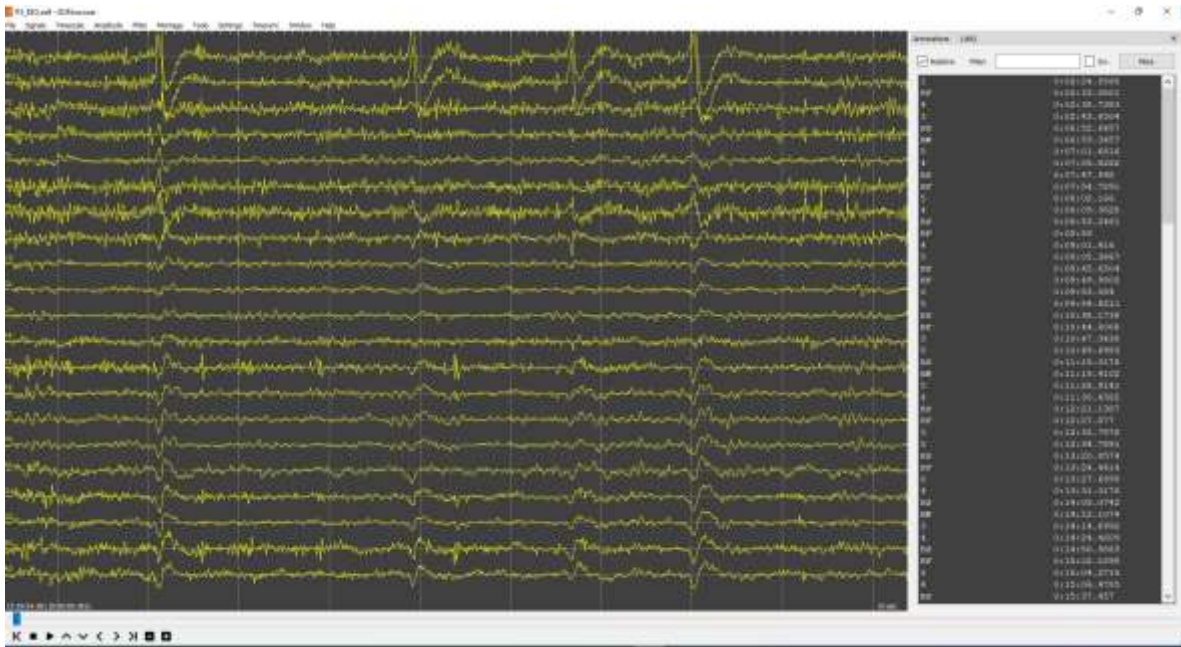


Ilustración 33 Visualización con EDFBrowser de la señal EEG en crudo , tras haber aplicado procesamiento mediante filtros de paso banda y CAR, además de reconstrucción de artefactos con ASR e identificación y segmentación de las épocas, en la parte derecha se puede visualizar las anotaciones generadas para cada uno de los eventos de BS.

3.1.3. Determinar y aplicar técnicas de análisis de datos a partir de técnicas de clasificación y aprendizaje automático que aproximen la caracterización de mente divagante

3.1.3.1. *Classification / Pipeline de Clasificación de Neuro señales*

Habiendo realizado la correspondiente segmentación en épocas a la señal EEG, se aplican los filtros mostrados a continuación

3.1.3.2. *Filtrado pasa banda en Frecuencia*

Basado en los hallazgos de (Rodríguez-Larios & Alarerts, 2021) para los cuales se evidencian condiciones relacionadas con las modulaciones promedio de las frecuencias theta (4–8 Hz) y alfa (8–14 Hz). En donde las estadísticas de permutación revelaron una frecuencia alfa media más alta y una frecuencia media theta más baja durante mente divagante MW en relación con atención centrada en la respiración BF. Se decide aplicar un filtrado paso banda entre los 4 y 14 Hz a la luz de esta evidencia.

3.1.3.3. *Filtrado Espacial*

El sistema típico de clasificación de neuro señales está separado por tres partes principales: preprocesamiento, extracción de características y clasificación de los patrones del EEG. En este artículo, nuestro método propuesto principalmente para los pasos de extracción de características. Antes del paso de extracción de características, necesitamos un filtrado espacial que actúe sobre las señales de EEG. El propósito del filtro espacial es reducir el efecto de desenfoque espacial de la señal sin procesar. El desenfoque espacial se produce como efecto de la distancia entre el sensor y las fuentes de señales en el cerebro, debido a la falta de homogeneidad de los tejidos entre las áreas del cerebro.(Yu et al., 2014)

3.1.3.3.1. Patrones Comunes Espaciales (CSP)

En los últimos años, dos técnicas que explotan la información de covarianza de las señales EEG han demostrado una destacable capacidad discriminante en un sin número de retos internacionales sobre bancos de datos disponibles por parte de la comunidad científica para fines de comparación. Las primeras utilizan la información de covarianza para la construcción de filtros supervisados espaciales, denominadas patrones comunes espaciales (CSP), junto con técnicas de clasificación clásicas como el análisis discriminante cuadrático/lineal o máquinas de vectores de soporte. En la otra técnica, la información de covarianza es tratada como patrón característico de la señal EEG y su tratamiento se realiza en una variedad de Riemann. Dada la naturaleza espacial de esta señal, se pueden concebir filtros espaciales para poder realzar características que permitan discriminar entre los dos tipos de estados mentales en este tipo de señales. De hecho, los filtros espaciales han sido ampliamente utilizados en investigaciones en neurociencia y neuro ingeniería en todo el mundo. Se utilizan principalmente para aumentar la relación señal ruido de la señal EEG (Ferrin Bolaños et al., 2019).

El CSP tiene como propósito inicial aplicar filtros (Sin aplicar varianza logarítmica) de manera supervisada para aumentar la varianza de unos canales para una clase y disminuir lo de otros para la otra clase. La mejor forma de caracterizar una señal EEG con este filtro es ser aplicado de manera previa a una extracción de características basadas en varianza logarítmica. Los CSP se construyen de forma supervisada, esto es, teniendo en cuenta la clase a la que pertenece cada segmento de señal EEG. Para la obtención de este filtro se parte del problema de maximización del cociente Rayleigh asociado a las matrices de covarianza de los segmentos de señal relacionados con la mente divagante MW y mente concentrada en la respiración BF. Sean E_1 y E_2 segmentos de la señal EEG de N canales y h muestras para mente divagante MW (Clase 1) y concentración en la respiración BF (Clase 2). Las matrices de covarianza C_1 y C_2 asociadas a E_1 y E_2 respectivamente se obtienen mediante la siguiente expresión de la Ecuación 37 (Ferrin Bolaños et al., 2019).

$$C_i = \frac{E_i E_i^T}{\text{tr}(E_i E_i^T)}, \quad i = 1, 2$$

Ecuación 37

En la Ecuación 37 $\text{tr}(\cdot)$ es el operador traza, esto es, la suma de los elementos de la diagonal principal de una matriz. Si C_i se calcula con $h > N$, entonces la probabilidad de que C_i sea invertible aumenta, garantizándose así que la matriz no solo sea simétrica sino también definida positiva.

La implementación de la descomposición de la señal EEG utilizando CSP en este proyecto se encuentra basada en MNE con la clase *mne.decoding.CSP* (Gramfort, 2013). Esta clase se puede utilizar como una descomposición supervisada para estimar filtros espaciales para la extracción de características (Koles et al., 1990). MNE es un paquete de Python de código abierto para explorar, visualizar y analizar datos neurofisiológicos humanos entre ellos EEG.

3.1.3.3.2. XDawn

Xdawn es un método de filtrado espacial diseñado para mejorar la relación señal a señal + ruido (SSNR) de las respuestas de ERP. Xdawn fue diseñado originalmente para el potencial evocado P300 al mejorar la respuesta del objetivo con respecto a la respuesta del no objetivo. Esta implementación es una generalización a cualquier tipo de ERP (Rivet et al., 2009).

Esta implementación se encuentra basada en pyRiemann (Barachant et al., 2012, 2013) que es un paquete de Python para la manipulación y clasificación de matrices de covarianza a través de la geometría de Riemann. Utilizando la clase Xdawn de los filtros espaciales. Este paquete tiene como objetivo adoptar las convenciones Scikit-Learn y MNE-Python que corresponden a las librerías utilizadas en el pipeline de filtrado y clasificación de neuro señales en esta investigación.

Este filtro es aplicado a lo largo de los 4 pipelines propuestos para la clasificación de mente divagante, con la finalidad de analizar su desempeño del filtro, sin embargo, no es considerado en el momento de ejecutar el pipeline.

3.1.3.4. *Extracción de características*

3.1.3.4.1. **Espacio Tangente**

La proyección del espacio tangente mapea un conjunto de matrices de covarianza a su espacio tangente de acuerdo con (Barachant et al., 2012; Ferrin Bolaños et al., 2019). La proyección del espacio tangente puede verse como una operación del núcleo, cf (Barachant et al., 2013). Después de la proyección, cada matriz se representa como un vector de tamaño: $N(N + 1) / 2$ donde N es la dimensión de las matrices de covarianza.

La proyección espacial tangente es útil para convertir matrices de covarianza en vectores euclidianos mientras se conserva la estructura interna de la variedad. Después de la proyección, se puede aplicar el procesamiento estándar y la clasificación basada en vectores. La proyección espacial tangente es una aproximación local de la variedad. toma un parámetro, el punto de referencia, que generalmente se estima usando la media geométrica del conjunto de matrices de covarianza que proyecta. si no se llama a la función de ajuste `fit`, la matriz de identidad se utilizará como punto de referencia. Esto puede provocar una degradación grave del rendimiento. La aproximación será mayor si las matrices del conjunto están dispersas en la variedad y menor si están agrupadas en una pequeña región de la variedad. Después de la proyección, es posible retroceder en el colector usando la transformada inversa. (Barachant et al., 2012, 2013).

Esta implementación se encuentra basada en pyRiemann (Barachant et al., 2012, 2013) que es un paquete de Python para la manipulación y clasificación de matrices de covarianza a través de la geometría de Riemann. Utilizando la clase TangentSpace. Este paquete tiene como objetivo adoptar las convenciones Scikit-Learn y MNE-Python mediante las funciones de ajuste y entrenamiento, que corresponden a las librerías utilizadas en el pipeline de filtrado y clasificación de neuro señales en esta investigación.

3.1.3.4.1.1. *Geometría de Riemann para clasificación de Mente Divagante*

Esta técnica se utiliza para calcular la matriz vectorizada promedio de una señal EEG. El procedimiento consiste en tomar la señal EEG y obtener la matriz de covarianza, la cual es proyectada en el espacio tangente de la matriz de covarianza promedio de los datos de entrenamiento independientemente de la clase (Ferrin Bolaños et al., 2019). A continuación, se detalla su modelo matemático:

Las matrices de covarianza simétricas y definidas positivas, C_i (Ecuación 37), pueden ser utilizadas como representación de las señales EEG, E_i . Este tipo de matrices simétricas y definidas positivas pertenecen a una forma particular de variedad matemática conocida como variedad de Riemann, $C(N)$. En esta variedad matemática, la distancia Riemanniana de dos matrices, C_1 y C_2 , viene dada por la Ecuación 38 (Ferrin Bolaños et al., 2019)

$$\delta_R(C_1, C_2) = \|\text{Log}(C_1^{-1}C_2)\|_F = \left[\sum_{n=1}^N \log^2 \beta_n \right]^{1/2}$$

Ecuación 38

Donde β_n son los autovalores de $C_1^{-1}C_2$. $\text{Log}(C = C_1^{-1}C_2)$ es el logaritmo de una matriz, el cual se calcula, con ayuda de la descomposición en valores singulares de C mediante el siguiente producto de matrices: $U(\text{diag}[\ln(\beta_1), \dots, \ln(\beta_n)])U^T$ donde U es la matriz de autovectores de C. $\|\cdot\|_F$ es la norma de Frobenius de una matriz, la cual se obtiene como la raíz cuadrada de la traza del producto entre la matriz y su transpuesta. Para utilizar esta distancia en un problema de clasificación de señales E_i , se obtienen matrices promedio, una para la clase 1, \overline{C}_1 y otra para la clase 2, \overline{C}_2 . La discriminación de una matriz C se hace por menor distancia a las matrices promedio anteriores. Para encontrar estas matrices promedio, no es posible utilizar la fórmula de medios de aritmética de matrices convencionales, utilizada en la sección anterior, ya que las matrices de covarianza no residen en el espacio euclídeo sino en una variedad Riemanniana. En este espacio la matriz promedio asociado a M_1 , matrices de covarianza para la clase 1 y M_2 matrices de covarianza para la clase 2, se obtiene resolviendo los siguientes problemas de optimización respectivamente:

$$\overline{C}_1 = \arg \min_{C \in C(n)} \sum_{i=1}^{M_1} \delta_R(C, C_{i1})$$

Ecuación 39

$$\overline{C}_2 = \arg \min_{C \in C(n)} \sum_{i=1}^{M_2} \delta_R(C, C_{i2})$$

Ecuación 40

No hay una forma explícita para resolver el problema anterior, pero existen formas iterativas para estimarlo, utilizando el concepto de espacio tangente. Con ayuda del logaritmo Riemanniano entre dos matrices, $\text{LogR}(C, C_i)$, se proyecta el conjunto de datos completo, C_i ($i=1\dots M$), matrices de covarianza, en el espacio tangente de C. En este espacio, por cierto, de propiedades euclidianas, el promedio puede obtenerse mediante media aritmética. Finalmente, se re proyecta este promedio obtenido al espacio SPD mediante la exponencial Riemanniana entre dos matrices, $\text{ExpR}(C, C_i)$. Después de algunas iteraciones, se obtiene la media geométrica de las matrices SPD. Las iteraciones se detienen cuando se ha realizado un número determinado de iteraciones o cuando la distancia de Frobenius de la proyección tangente promedio se hace estacionaria (Ver Tabla 3).

Tabla 3 Algoritmo para promedio de matrices de covarianza

Entrada: - Un conjunto de M matrices de covarianza, $C_i \in C(N)$.
 Valor de tolerancia, θ .
 Valor máximo de iteraciones, \maxIter .

Salida: - Matriz promedio estimada \bar{C} .

- 1: Inicializar $\bar{C}^{(0)} = \frac{1}{M} \sum_{i=1}^M C_i$
- 2: Calcular $S = \frac{1}{M} \sum_{i=1}^M \text{Log}_R(\bar{C}^{(0)}, C_i)$
- 3: $k = 0$
- 4: **mientras** $k < \maxIter$ y $\theta > \|S\|_F$
- 5: $S = \frac{1}{M} \sum_{i=1}^M \text{Log}_R(\bar{C}^{(k)}, C_i)$
- 6: $\bar{C}^{(k+1)} = \text{Exp}_R(\bar{C}^{(k)}, S)$
- 7: $k = k + 1$.
- 8: **fin**
- 9: $\bar{C} = \bar{C}^{(k)}$
- 10: **retornar** \bar{C}

Las expresiones matemáticas para el logaritmo y exponencial Riemanniano para proyección y reproyección tangente, respectivamente, se muestran en la Ecuación 41 con la matriz de covarianza de los datos de entrenamiento y en la Ecuación 42 con la matriz promedio de toda la data de entrenamiento. Igualmente, estas operaciones se muestran en Ilustración 34

$$S_i = C^{1/2} \text{Log}(C^{-1/2} C_i C^{-1/2}) C^{1/2}$$

Ecuación 41

$$C_i = C^{1/2} \text{Exp}(C^{-1/2} S_i C^{-1/2}) C^{1/2}$$

Ecuación 42

Para la construcción de filtros y de clasificadores en el espacio tangente, las matrices de covarianza proyectadas, las cuales son simétricas, $S_{i,j} = S_{j,i}$, pueden vectorizarse utilizando únicamente su parte triangular superior como se muestra en la Ecuación 43 (Ferrin Bolaños et al., 2019)

$$\text{vect}(S) = \begin{bmatrix} S_{(1,1)} \\ \sqrt{2}S_{(1,2)} \\ \vdots \\ \sqrt{2}S_{(1,N)} \\ S_{(2,2)} \\ \sqrt{2}S_{(2,3)} \\ \vdots \\ \sqrt{2}S_{(2,N)} \\ \vdots \\ S_{(N,N)} \end{bmatrix}$$

Ecuación 43




Ilustración 34 Espacio tangente de una matriz de covarianza C , la cual pertenece a la variedad Riemanniana $C(N)$. Si es la proyección de C_i en el espacio tangente de C Tomando de (Ferrin Bolaños et al., 2019)

3.1.3.4.2. Varianza Logarítmica

La varianza logarítmica consiste en calcular la varianza para cada uno de los valores de los canales y posteriormente aplicar Logaritmo, con esto se pasa de la señal EEG al patrón. Para calcular la varianza se aplica logaritmo ya que los valores obtenidos son muy grandes y esto se hace con la finalidad de hacerlos más pequeños. (Ferrin Bolaños et al., 2019)

$$e_i = \langle \ln(WE_i) \rangle$$

3.1.3.4.3. Técnicas de extracción de Características basadas en PyEEG

PyEEG es una herramienta de Neurociencia Computacional que se centra en la extracción de características de segmentos EEG/EMG. (Bao et al., 2011). Las técnicas de extracción de características soportadas por esta librería se listan a continuación:

Tabla 4 Lista de técnicas de extracción de características con sus correspondientes tipos de datos de retorno en PyEEG (Bao et al., 2011)

Feature name	Function name	Return type
Power Spectral Intensity (PSI) and Relative Intensity Ratio (RIR)	bin_power()	Two 1-D vectors
Petrosian Fractal Dimension (PFD)	pdf()	A scalar
Higuchi Fractal Dimension (HFD)	hfd()	A scalar
Hjorth mobility and complexity	hjorth()	Two scalars
Spectral Entropy (Shannon's entropy of RIRs)	spectral_entropy()	A scalar
SVD Entropy	svd_entropy()	A scalar
Fisher Information	fisher_info()	A scalar
Approximate Entropy (ApEn)	ap_entropy()	A scalar
Detrended Fluctuation Analysis (DFA)	dfa()	A scalar
Hurst Exponent (Hurst)	hurst()	A scalar

Dentro de las cuales se han seleccionado las siguientes para extracción de características en el contexto de mente divagante: Exponente de Hurst, Análisis de fluctuación de desviación de tendencia (DFA Detrended Fluctuation Analysis), Dimensión fractal Petrosiana (PFD Petrosian Fractal Dimension), Dimensión Fractal Higuchi (HFD Higuchi Fractal Dimension), Entropía de Descomposición de valores Singulares (SVD Singular Value Decomposition), Entropía aproximada (ApEn Approximate entropy) y Entropía de permutación.

3.1.3.4.3.1. Exponente de Hurst

El exponente de hurst (HURST) (Bao et al., 2011) también se denomina estadísticas de rango re escalado (R / S). Para calcular el exponente de Hurst para la serie de tiempo $X = [x_1, x_2, \dots, x_N]$, el primer paso es calcular la desviación acumulada de la media de la serie de tiempo dentro del rango T.

$$X(t, T) = \sum_{i=1}^t (x_i - \bar{x}), \quad \text{where } \bar{x} = \frac{1}{T} \sum_{i=1}^T x_i, \quad t \in [1..N].$$

Ecuación 44

Entonces, $R(T) / S(T)$ se calcula como

$$\frac{R(T)}{S(T)} = \frac{\max(X(t,T)) - \min(X(t,T))}{\sqrt{(1/T) \sum_{t=1}^T [x(t) - \bar{x}]^2}}$$

Ecuación 45

El exponente de Hurst se obtiene calculando la pendiente de la línea producida por $\ln(R(n)/S(n))$ versus $\ln(n)$ para $n \in [2..N]$. Hurst Exponent es una función escalar.

3.1.3.4.3.2. Análisis de fluctuación de desviación de tendencia (DFA Detrended Fluctuation Analysis)

Los procedimientos para calcular DFA de una serie de tiempo $[x_1, x_2, \dots, x_N]$ son los siguientes.

1. Primero integrar x en una nueva serie $y = [y(1), \dots, y(N)]$, donde $y(k) = \sum_{i=1}^k (x_i - \bar{x})$ es el promedio de x_1, x_2, \dots, x_N .
2. A continuación, la serie integrada se corta en cajas de igual longitud n . En cada cuadro de longitud n , se ajusta una línea de mínimos cuadrados a los datos, que representa la tendencia en ese cuadro. La coordenada y de los segmentos de línea recta se denota por $y_n(k)$.
3. La fluctuación cuadrática media de la serie integrada se calcula mediante $F(n) = \sqrt{(1/N) \sum_{k=1}^N [y(k) - y_n(k)]^2}$, donde la parte $y(k) - y_n(k)$ se llama detrending o desviación (sin) de tendencia.
4. La fluctuación se puede definir como la pendiente de la línea que relaciona $\log F(n)$ con $\log n$.

3.1.3.4.3.3. *Los Dimensión fractal Petrosiana (PFD Petrosian Fractal Dimension)*

Para una serie de tiempo, PFD se define como

$$PFD = \frac{\log_{10} N}{\log_{10} N + \log_{10} (N / (N + 0.4N_{\delta}))},$$

Ecuación 46

donde N es la longitud de la serie y N_{δ} es el número de cambios de signo en la derivada de la señal (Bao et al., 2011). PFD es una característica escalar.

3.1.3.4.3.4. *Dimensión Fractal de Higuchi (HFD Higuchi Fractal Dimension)*

El algoritmo de Higuchi (Bao et al., 2011) construye k series nuevas a partir de la serie original $[x_1, x_2, \dots, x_N]$ por

$$x_m, x_{m+k}, x_{m+2k}, \dots, x_{m+\lfloor (N-m)/k \rfloor k},$$

Ecuación 47

donde $m = 1, 2, \dots, k$.

Para cada serie de tiempo construida a partir de la Ecuación 47, la longitud $L(m, k)$ se calcula mediante

$$L(m, k) = \frac{\sum_{i=2}^{\lfloor (N-m)/k \rfloor} |x_{m+ik} - x_{m+(i-1)k}| (N-1)}{\lfloor (N-m)/k \rfloor k}.$$

Ecuación 48

La longitud media se calcula como $L(k) = [\sum_{i=1}^k L(i, k)] / k$.

Este procedimiento repite k_{\max} veces para cada k de 1 a k_{\max} , y luego usa un método de mínimos cuadrados para determinar la pendiente de la línea que mejor se ajusta a la curva de $\ln(L(k))$ versus $\ln(1/k)$. La pendiente es la Dimensión Fractal de Higuchi. HFD es una característica escalar.

3.1.3.4.3.5. *Entropía de Descomposición de valores Singulares (SVD Singular Value Decomposition)*

(Bao et al., 2011) define una medida de entropía mediante la descomposición de valores singulares (SVD). Sea la señal de entrada $[x_1, x_2, \dots, x_N]$. Construimos vectores de retardo como

$$y(i) = [x_i, x_{i+\tau}, \dots, x_{i+(d_E-1)\tau}],$$

Ecuación 49

donde τ es el retraso y d_E es la dimensión de inclusión. En este artículo, $d_E = 20$ y $\tau = 2$. El espacio de incrustación se construye luego por

$$Y = [y(1), y(2), \dots, y(N-(d_E-1)\tau)]^T.$$

Ecuación 50

Luego, la SVD se realiza en la matriz Y para producir M valores singulares, $\sigma_1, \dots, \sigma_M$, conocido como el espectro singular.

La entropía SVD se define entonces como:

$$H_{SVD} = - \sum_{i=1}^M \bar{\sigma}_i \log_2 \bar{\sigma}_i,$$

Ecuación 51

donde M es el número de valores singulares y $\bar{\sigma}_1, \dots, \bar{\sigma}_M$ son valores singulares normalizados tales que $\bar{\sigma}_i = \sigma_i / \sum_{j=1}^M \sigma_j$. La entropía SVD es una característica escalar.

3.1.3.4.3.6. Información de Fisher

La información de Fisher (Bao et al., 2011) se puede definir en el espectro singular normalizado utilizado en la Ecuación 51

$$I = \sum_{i=1}^{M-1} \frac{(\bar{\sigma}_{i+1} - \bar{\sigma}_i)^2}{\bar{\sigma}_i}.$$

Ecuación 52

La información de Fisher es una característica escalar.

3.1.3.4.3.7. Entropía aproximada (ApEn Approximate entropy)

La entropía aproximada (ApEn) es un parámetro estadístico para cuantificar la regularidad de una serie temporal (Bao et al., 2011).

ApEn se calcula mediante los siguientes pasos.

1. Sea la señal de entrada $[x_1, x_2, \dots, x_N]$.
2. Construya la subsecuencia $x(i, m) = [x_i, x_{i+1}, \dots, x_{i+m-1}]$ para $1 \leq i \leq N - m$, donde m es la longitud de la subsecuencia. En (Bao et al., 2011), $m = 1, 2$ o 3 .
3. Sea r el nivel del filtro de ruido, definido como $r = k \times SD$ para $k = 0, 0.1, 0.2, \dots, 0.9$.
4. Construya un conjunto de subsecuencias $\{x(j, m)\} = \{x(j, m) \mid j \in [1..N - m]\}$, donde $x(j, m)$ i se define en el paso 2.
5. Para cada $x(i, m) \in \{x(j, m)\}$, calcule

$$C(i, m) = \frac{\sum_{j=1}^{N-m} k_j}{N-m},$$

Ecuación 53

Donde:

$$k_j = \begin{cases} 1 & \text{if } |x(i, m) - x(j, m)| < r, \\ 0 & \text{otherwise.} \end{cases}$$

Ecuación 54

$$\text{ApEn}(m, r, N) = \frac{1}{N - M} \left[\sum_{i=1}^{N-m} \ln \frac{C(i, m)}{C(i, m + 1)} \right].$$

Ecuación 55

ApEn es una característica escalar

3.1.3.4.3.8. Entropía de permutación

Calcula la entropía de permutación de una serie de tiempo dada x , especificada por el orden de permutación n y el retardo de incrustación τ (Bao et al., 2011).

Suponga que la serie de tiempo dada es $X = [x(1), x(2), x(3), \dots, x(N)]$. Primero construimos la matriz de incrustación E_m , de dimensión $(n * N - n + 1)$, tal que la i -ésima fila de E_m es $x(i), x(i + 1), \dots, x(i + n - 1)$. Por lo tanto, el retardo de inserción y la dimensión de inserción son 1 y n respectivamente. Construimos esta matriz a partir de una serie de tiempo dada, X , llamando a la función `pyEEg embed_seq(x, 1, n)`.

Luego transformamos cada fila de la matriz de incrustación en una nueva secuencia, que comprende un conjunto de números enteros en el rango de 0, ..., $n - 1$. El orden en el que se colocan los números enteros dentro de una fila es el mismo que el de los elementos originales: 0 se coloca dónde estaba el elemento más pequeño de la fila y $n - 1$ reemplaza el elemento más grande de la fila.

Para calcular la entropía de permutación, calculamos la entropía de `PeSeq`. Al hacerlo, contamos el número de ocurrencias de cada permutación en `PeSeq` y lo escribimos en una secuencia, `RankMat`. Luego usamos esta secuencia para calcular la entropía usando la fórmula de entropía de Shannon. La entropía de permutación generalmente se calcula con n en el rango de 3 y 7. (Bao et al., 2011).

3.1.3.5. Clasificación con Aprendizaje Automático

La librería utilizada para la clasificación de los estados mentales relacionados con mente divagante MW y concentración en la respiración BF es **Scikit-learn** es una biblioteca de aprendizaje automático de código abierto que admite el aprendizaje supervisado y no supervisado. También proporciona varias herramientas para el ajuste de modelos, preprocesamiento de datos, selección y evaluación de modelos y muchas otras utilidades. (Pedregosa et al., 2011).

Scikit-learn proporciona docenas de algoritmos y modelos de aprendizaje automático integrados para **predicción y ajuste**, llamados "**estimadores**". Cada estimador se puede ajustar a algunos datos utilizando su método de ajuste "**fit**". Por ejemplo, implementación de árboles aleatorios basados en árboles de decisión con mediante la clase `RandomForestClassifier` (Pedregosa et al., 2011).

Los flujos de trabajo de aprendizaje automático a menudo se componen de diferentes partes. Una canalización típica consta de un paso de preprocesamiento que transforma o imputa los datos y un predictor final que predice los valores objetivo. En scikit-learn, los **preprocesadores** y los **transformadores** siguen la misma API que los objetos estimadores (en realidad, todos heredan de

la misma clase “*BaseEstimator*”). Los objetos transformadores no tienen un método de predicción “*predict*”, sino un método de transformación “*transform*” que genera una matriz de muestra *X* recién transformada: (Pedregosa et al., 2011).

```
>>> from sklearn.preprocessing import StandardScaler
>>> X = [[0, 15],
...      [1, -10]]
>>> # scale data according to computed scaling values
>>> StandardScaler().fit(X).transform(X)
array([[ -1.,   1.],
       [  1.,  -1.]])
```

Los transformadores y estimadores (predictores) se pueden combinar en un solo objeto unificador: llamado **Pipeline**. Los pipelines ofrecen la misma API que un estimador regular: se puede ajustar y utilizar para la predicción con ajuste “*fit*” y predicción “*predict*” (Pedregosa et al., 2011).

Ajustar un modelo a algunos datos no implica que predecirá bien sobre datos previamente no validados por el modelo. Para la **evaluación del modelo** debe hacerse directamente. Mediante la función *train_test_split* que divide un conjunto de datos en conjuntos de prueba y de entrenamiento, pero scikit-learn proporciona muchas otras herramientas para la evaluación de modelos, en particular para la validación cruzada. (Pedregosa et al., 2011). En esta investigación se implementó inicialmente evaluación del modelo *mediante validación cruzada X10*, una vez que la fase exploratoria de demostró que los datos se encontraban desbalanceados se optó por una técnica estadística basado en análisis no paramétrico como *Comparaciones estadísticas de clasificadores sobre múltiples conjuntos de datos*.

Todos los estimadores tienen parámetros (a menudo llamados *hiperparámetros* en la literatura) que se pueden ajustar. El poder de generalización de un estimador a menudo depende críticamente de algunos parámetros. Scikit-learn proporciona herramientas para encontrar automáticamente las mejores combinaciones de parámetros (mediante validación cruzada). (Pedregosa et al., 2011). Dado el objetivo general y la hipótesis planteada para este proyecto de investigación, el ajuste de *hiperparámetros* se da en función de los parámetros por defecto de cada una de las técnicas empleadas.

3.1.3.5.1. Análisis discriminante lineal: LinearDiscriminantAnalysis

El análisis discriminante lineal LDA es un clasificador clásico, con una superficie de decisión lineal. Este clasificador es atractivo porque tiene soluciones de forma cerrada de tal manera que se pueda calcular fácilmente, es intrínsecamente multiclase, ha demostrado funcionar bien en la práctica y no tiene hiperparámetros para ajustar (Pedregosa et al., 2011).




Ilustración 35 Análisis discriminante lineal , izquierda: Datos con covarianza fija, derecha: datos con covarianza variante
El gráfico muestra los límites de decisión para el análisis discriminante lineal. el análisis discriminante lineal solo puede aprender límites lineales. (Pedregosa et al., 2011)

La formulacion matematica del clasificador LDA, puede derivarse de modelos probabilísticos simples que modelan la distribución condicional de clase de los datos $P(X|y = k)$ para cada clase k . Luego, se pueden obtener predicciones utilizando la regla de Bayes, para cada muestra de entrenamiento $x \in R^d$.

$$P(y = k|x) = \frac{P(x|y = k)P(y = k)}{P(x)} = \frac{P(x|y = k)P(y = k)}{\sum_l P(x|y = l) \cdot P(y = l)}$$

Ecuación 56

y seleccionamos la clase K que maximiza esta probabilidad posterior. Más específicamente, para el análisis discriminante lineal, $P(x|y)$ se modela como una distribución gaussiana multivariante con densidad:

$$P(x|y = k) = \frac{1}{(2\pi)^{d/2}|\Sigma_k|^{1/2}} \exp\left(-\frac{1}{2}(x - \mu_k)^t \Sigma_k^{-1}(x - \mu_k)\right)$$

Ecuación 57

donde d es el número de características.

LDA es un caso especial de analisis discriminante cuadratico, donde se supone que los gaussianos de cada clase comparten la misma matriz de covarianza: $\Sigma_k = \Sigma$

Para todos los k . Esto reduce el registro posterior a:

$$\log P(y = k|x) = -\frac{1}{2}(x - \mu_k)^t \Sigma^{-1}(x - \mu_k) + \log P(y = k) + Cst.$$

Ecuación 58

El término $(x - \mu_k)^t \Sigma^{-1} (x - \mu_k)$ corresponde a la distancia de Mahalanobis entre la muestra x y la media μ_k . La distancia de Mahalanobis indica qué tan cerca está x de μ_k , mientras que también tiene en cuenta la variación de cada característica. Por lo tanto, podemos interpretar que LDA asigna a la clase x cuya media es la más cercana en términos de la distancia de Mahalanobis, mientras que también considera las probabilidades previas de la clase.

La implementación de este clasificador para la clasificación de mente divagante se encuentra basado en la clase `sklearn.discriminant_analysis.LinearDiscriminantAnalysis` de Scikit-learn. Implementa un clasificador con un límite de decisión lineal, generado ajustando densidades condicionales de clase a los datos y utilizando la regla de Bayes. El modelo ajusta una densidad gaussiana a cada clase, asumiendo que todas las clases comparten la misma matriz de covarianza. El modelo ajustado también se puede utilizar para reducir la dimensionalidad de la entrada proyectándola en las direcciones más discriminatorias, utilizando el método de transformación (Pedregosa et al., 2011). El método utilizado es *Descomposición en valores singulares* que es una factorización de una matriz real o compleja. Generaliza la descomposición propia de una matriz normal cuadrada con una base propia ortonormal a cualquier matriz $m \times n$.

3.1.3.5.2. Máquinas de Soporte Vectorial / de Vector de soporte: SVC

Las máquinas de vectores de soporte (SVM) son un conjunto de métodos de aprendizaje supervisado que se utilizan para la clasificación, la regresión y la detección de valores atípicos (Pedregosa et al., 2011).

- Las ventajas de las máquinas de vectores de soporte son:
- Efectivo en espacios de gran dimensión.
- Sigue siendo eficaz en los casos en que el número de dimensiones es mayor que el número de muestras.
- Utiliza un subconjunto de puntos de entrenamiento en la función de decisión (llamados vectores de soporte), por lo que también es eficiente en la memoria.
- Versátil: se pueden especificar diferentes funciones del Kernel para la función de decisión. Se proporcionan núcleos comunes, pero también es posible especificar núcleos personalizados.




Ilustración 36 Grafico de SVC con kernel lineal donde se puede observar el tamaño de los sépalos en longitud en el eje x y ancho en el eje Y tomado de (Pedregosa et al., 2011)

La formulación matemática: Una máquina de vectores de soporte construye un hiperplano o un conjunto de hiperplanos en un espacio dimensional alto o infinito, que se puede utilizar para clasificación, regresión u otras tareas. Intuitivamente, se logra una buena separación por el hiperplano que tiene la mayor distancia a los puntos de datos de entrenamiento más cercanos de cualquier clase (el llamado margen funcional), ya que en general cuanto mayor es el margen menor es el error de generalización del clasificador. La siguiente figura muestra la función de decisión para un problema linealmente separable, con tres muestras en los límites del margen, llamadas "vectores de soporte" (Pedregosa et al., 2011):




Ilustración 37 función de decisión para un problema linealmente separable, con tres muestras en los límites del margen, llamadas "vectores de soporte" (Pedregosa et al., 2011)

En general, cuando el problema no es separable linealmente, los vectores de soporte son las muestras dentro de los límites del margen.

Dados los vectores de entrenamiento, $x_i \in \mathbb{R}^p, i=1, \dots, n$, en dos clases y un vector, $y \in \{1, -1\}^n$, nuestro objetivo es encontrar $w \in \mathbb{R}^p$ de tal manera que la predicción dada por $\text{sign}(w^T \phi(x) + b)$ sea correcta para la mayoría de las muestras.

SVC resuelve el siguiente problema principal:

$$\begin{aligned} \min_{w, b, \zeta} \quad & \frac{1}{2} w^T w + C \sum_{i=1}^n \zeta_i \\ \text{subject to} \quad & y_i (w^T \phi(x_i) + b) \geq 1 - \zeta_i, \\ & \zeta_i \geq 0, i = 1, \dots, n \end{aligned}$$

Ecuación 59

Intuitivamente, estamos tratando de maximizar el margen (minimizando $\|w\|^2 = w^T w$), mientras incurrimos en una penalización cuando una muestra está mal clasificada o dentro del límite

del margen. Idealmente, el valor $y_i(w^T \phi(x_i) + b)$ sería ≥ 1 para todas las muestras, lo que indica una predicción perfecta. Pero los problemas no siempre son perfectamente separables con un hiperplano, por lo que permitimos que algunas muestras estén a una distancia ζ_i de su límite de margen correcto. El término de penalización C controla la fuerza de esta penalización y, como resultado, actúa como un parámetro de regularización inverso (ver nota a continuación) (Pedregosa et al., 2011).

La implementación de este clasificador para el presente estudio se encuentra basado en vectores de soporte de clasificación, para realizar clasificaciones binarias de set de datos, utilizando la clase *sklearn.svm.SVC* de Scikit-learn. La implementación del SVC se basa en libsvm. El tiempo de ajuste "fit" se escala al menos cuadráticamente con el número de muestras y puede resultar poco práctico más allá de decenas de miles de muestras. El soporte multiclase se maneja de acuerdo con un esquema de uno contra uno (Pedregosa et al., 2011).

El parametro de regularizacion utilizado es el por defecto 1.0 y el tipo de kernel utilizado en el algoritmo es lineal (x, x') .

3.1.3.5.3. Regresión logística: LogisticRegression

La regresión logística, es un modelo lineal de clasificación más que de regresión. La regresión logística también se conoce en la literatura como regresión logit, clasificación de máxima entropía (MaxEnt) o clasificador log-lineal. En este modelo, las probabilidades describen los posibles resultados de una prueba simple son modelados utilizando una **función logística** (Pedregosa et al., 2011).

La formulación matemática de la regresión logística puede expresarse de manera simple a través de una función o curva logística, que es una curva en forma de S común (curva sigmoidea) con la ecuación,

$$f(x) = \frac{L}{1 + e^{-k(x-x_0)}}$$

Ecuación 60

En donde

x_0 es el valor x del punto medio del sigmoide;

L es el valor máximo de la curva;

K la tasa de crecimiento logístico o la pendiente de la curva.




Ilustración 38 Función sigmoide logística estándar donde $L=1$, $K=1$, $x_0 = 0$

La regresión logística para la clasificación de mente divagante se implementa en la clase `sklearn.linear_model.LogisticRegression` de scikit-learn (Pedregosa et al., 2011). Esta implementación puede ajustarse a la regresión logística binaria, One-vs-Rest o multinomial con opcional ℓ_1 , ℓ_2 o regularización Elastic-Net. Los detalles de la implementación incluyen el término de penalización L2 y como la opción predeterminada. El algoritmo utilizado para el problema de optimización por defecto es **lbfgs** que es un método de optimización quasi-Newton de funciones que hace un uso limitado de la memoria y permite obtener el mínimo de una función. Utiliza un número máximo de 100 iteraciones para que el solucionador converja (Pedregosa et al., 2011).

3.1.3.5.4. Clasificador Perceptrón Multicapa: MLPClassifier

Perceptrón multicapa (MLP) es un algoritmo de aprendizaje supervisado que aprende una función $f(\cdot) : R^m \rightarrow R^o$ mediante el entrenamiento en un conjunto de datos, donde m es el número de dimensiones para la entrada y o es el número de dimensiones para la salida. Dado un conjunto de características $X = x_1, x_2, \dots, x_m$ y un objetivo (target) y , puede aprender un aproximador de función no lineal para clasificación o regresión. Es diferente de la regresión logística, en que entre la capa de entrada y la de salida, puede haber una o más capas no lineales, llamadas capas ocultas. La Ilustración 39 muestra un MLP de una capa oculta con salida escalar (Pedregosa et al., 2011).




Ilustración 39 Perceptrón multicapa (MLP) de una sola capa oculta.

La capa más a la izquierda, conocida como capa de entrada, consta de un conjunto de neuronas $\{x_i | x_1, x_2, \dots, x_m\}$ que representa las características de entrada. Cada neurona de la capa oculta transforma los valores de la capa anterior con una suma lineal ponderada, $w_1x_1 + w_2x_2 + \dots + w_mx_m$, seguida de una función de activación $g(\cdot) : \mathbb{R} \rightarrow \mathbb{R}$ no lineal, como la función tan hiperbólica. La capa de salida recibe los valores de la última capa oculta y los transforma en valores de salida (Pedregosa et al., 2011).

Las ventajas del perceptrón multicapa son:

- Capacidad para aprender modelos no lineales.
- Capacidad para aprender modelos en tiempo real (aprendizaje en línea).

Las desventajas del perceptrón multicapa (MLP) incluyen:

- Los MLP con capas ocultas tienen una función de pérdida no convexa cuando existe más de un mínimo local. Por lo tanto, diferentes inicializaciones de peso aleatorio pueden llevar a una precisión de validación diferente.
- MLP requiere ajustar una serie de hiperparámetros, como la cantidad de neuronas, capas e iteraciones ocultas.
- MLP es sensible a la escala de características.

La formulación matemática del perceptrón multicapa, viene dada por un conjunto de pruebas de entrenamiento $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ donde $x_i \in \mathbb{R}^n$ y $y_i \in \{0, 1\}$, una capa oculta de una neurona MLP oculta aprende de la función $f(x) = W_2g(W_1^T x + b_1) + b_2$ donde $W_1 \in \mathbb{R}^m$, y $W_2, b_1, b_2 \in \mathbb{R}$ son parámetros del modelo. W_1, W_2 representan los

pesos de la capa de entrada y la capa oculta, respectivamente. Y b_1, b_2 representan la desviación añadida a la capa oculta y a la capa de salida, respectivamente $g(\cdot) : \mathbb{R} \rightarrow \mathbb{R}$ es la función de activación, definida por defecto como la tangente hiperbólica, y es dada como:

$$g(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$$

Ecuación 61

Para clasificación binaria $f(x)$ pasa a través de una función logística $g(z) = 1/(1 + e^{-z})$ para obtener la una salida entre 0 y 1. El umbral, definido en 0.5, realizara asignación de las muestras de la salida superiores a 0.5 como clase positiva, y el resto como clase negativa.

MLP utiliza diferentes funciones de pérdida según el tipo de problema. La función de pérdida para la clasificación es la entropía cruzada, que en el caso binario se da como,

$$Loss(\hat{y}, y, W) = -y \ln \hat{y} - (1 - y) \ln (1 - \hat{y}) + \alpha \|W\|_2^2$$

Ecuación 62

Donde $\alpha \|W\|_2^2$ es un término de regularización L2 (también conocido como penalización) que penaliza modelos complejos; y $\alpha > 0$ es un hiperparámetro no negativo que controla la magnitud de la penalización.

Para la regresión, MLP utiliza la función de pérdida de error cuadrado; Escrito como,

$$Loss(\hat{y}, y, W) = \frac{1}{2} \|\hat{y} - y\|_2^2 + \frac{\alpha}{2} \|W\|_2^2$$

Ecuación 63

A partir de pesos aleatorios iniciales, el perceptrón multicapa (MLP) minimiza la función de pérdida actualizando repetidamente estos pesos. Después de calcular la pérdida, una pasada hacia atrás la propaga desde la capa de salida a las capas anteriores, proporcionando a cada parámetro de peso un valor de actualización destinado a disminuir la pérdida. El algoritmo se detiene cuando alcanza un número máximo preestablecido de iteraciones; o cuando la mejora en la pérdida está por debajo de un cierto número pequeño. (Pedregosa et al., 2011)

La implementación para este constructo computacional que diferencia BF de MW se encuentra basada en la clase `sklearn.neural_network.MLPClassifier` de scikit-learn (Pedregosa et al., 2011). La cual implementa un algoritmo de perceptrón multicapa (MLP) que se entrena mediante **Backpropagation**. MLP se entrena en dos arreglos: arreglo X de tamaño (n_muestras, n_caracteristicas), que contiene las muestras de entrenamiento representadas como vectores de características de punto flotante; y matriz y de tamaño (n_muestras,) que contiene los valores objetivo (etiquetas de clase) para las muestras de entrenamiento. Después del ajuste (entrenamiento), el modelo puede predecir etiquetas para nuevas muestras. (Pedregosa et al., 2011)

La configuración de los parámetros del MLP, viene dada por un método optimizador que corresponde BFGS de memoria limitada, es un algoritmo de optimización de la familia de métodos cuasi-Newton que se aproxima al algoritmo de Broyden-Fletcher-Goldfarb-Shanno (BFGS) utilizando una cantidad limitada de memoria de computadora. Es un algoritmo popular para la estimación de parámetros en el aprendizaje automático. El problema objetivo del algoritmo es minimizar $f(\mathbf{x})$ sobre valores no restringidos del vector real \mathbf{x} donde f es una función escalar diferenciable. El perceptrón además utiliza un parámetro de regularización L2 por defecto de 0.00001, con un total de 5 neuronas en la segunda capa, y el parámetro 1 como el que determina la generación de números aleatorios para las ponderaciones y la inicialización de sesgo, con el fin de obtener resultados reproducibles en múltiples llamadas a funciones.

3.1.4. Validar el prototipo del sistema mediante pruebas que se llevaran a cabo sobre la interfaz

3.1.4.1. *Evaluación del desempeño*

Con el fin de dar una aproximación preliminar a la evaluación del rendimiento en la clasificación de mente, se evalúa el desempeño de las métricas por encima del nivel de azar (Combrisson & Jerbi, 2015) para cada uno de los pipelines de clasificación basados en aprendizaje automático presentados en la sección 3.1.3. para los cuales se utiliza **validación cruzada** de tipo K con 10 particiones, llamada también 10-fold cross-validation, esta técnica es utilizada para evaluar los resultados de un análisis estadístico y garantizar que son independientes de la partición entre datos de entrenamiento y prueba. Consiste en repetir y calcular la media aritmética obtenida de las medidas de evaluación sobre las diferentes particiones. Se utiliza en entornos donde el objetivo principal es la predicción y se quiere estimar la precisión de un modelo que se llevará a cabo a la práctica. Es una técnica muy utilizada en proyectos de inteligencia artificial para validar modelos generados.

El resultado de la fase de descubrimiento de datos, arrojó que los datos entre MW y BF se encuentra desbalanceados, Además de que la estimación del rendimiento del modelo a través de la validación cruzada de k veces puede ser ruidosa. Esto significa que cada vez que se ejecuta el procedimiento, se puede implementar una división diferente del conjunto de datos en k-particiones y, a su vez, la distribución de las puntuaciones de rendimiento puede ser diferentes, lo que da como resultado una estimación media diferente del rendimiento del modelo. La cantidad de diferencia en el rendimiento estimado de una ejecución de validación cruzada de k veces a otra depende del modelo que se está utilizando y del propio conjunto de datos. Una estimación ruidosa del rendimiento del modelo puede resultar frustrante, ya que puede no estar claro qué resultado se debe utilizar para comparar y seleccionar un modelo final para abordar el problema. Una solución para reducir el ruido en el rendimiento estimado del modelo es aumentar el valor k. Esto reducirá el sesgo en el rendimiento estimado del modelo, aunque aumentará la varianza: p. Ej. vincule más el resultado al conjunto de datos específico utilizado en la evaluación. Un enfoque alternativo es repetir el proceso de validación cruzada de k veces varias veces e informar el rendimiento medio en todos los pliegues y todas las repeticiones. Este enfoque se denomina generalmente **validación cruzada repetida de k veces**. (Kuhn & Johnson, 2013). La configuración de la validación cruzada que se aplicará será de 10 particiones con 3 repeticiones. La implementación de esta técnica de validación estadísticas utilizada se encuentra basada en la clase `sklearn.model_selection.RepeatedStratifiedKFold` de la librería Scikit-learn (Pedregosa et al., 2011)

Para determinar la evaluación del desempeño de este nuevo método se utiliza la métrica llamada Valor-F (denominada también F-score o medida-F) en **estadística es la medida de precisión que tiene una prueba**. Se emplea en la determinación de un valor único ponderado de la *precisión* y la *exhaustividad* de la prueba, donde la precisión es el número de resultados positivos verdaderos dividido por el número de todos los resultados positivos, incluidos los que no se identificaron correctamente, y la exhaustividad es el número de resultados positivos verdaderos dividido por el número de todas las muestras que deberían haber sido identificadas como positivas. La precisión también se conoce como valor predictivo positivo y la exhaustividad también se conoce como sensibilidad en la clasificación binaria de diagnóstico.

La puntuación F1o **F1-Score** es la media armónica de la precisión y la exhaustividad. El puntaje más genérico F_{β} aplica pesos adicionales, valorando uno de precisión o exhaustividad más que el otro.

El valor más alto posible de una puntuación F es 1.0, lo que indica una precisión y una exhaustividad perfectas, y el valor más bajo posible es 0, si la precisión o la exhaustividad es cero. La puntuación F1 también se conoce como coeficiente de Sørensen-Dice o coeficiente de similitud de datos (DSC).

La puntuación F1 o F1-Score usa la siguiente fórmula para evaluar el rendimiento de los predictores (Fawcett, 2006):

$$F1 = \frac{2(\textit{precision} * \textit{exhaustividad})}{\textit{precision} + \textit{exhaustividad}}$$

Donde:

$$\textit{exhaustividad} = \frac{\textit{verdaderos positivos}}{(\textit{verdaderos positivos} + \textit{falsos negativos})}$$

$$\textit{precision} = \frac{\textit{verdaderos positivos}}{(\textit{verdaderos positivos} + \textit{falsos positivos})}$$

Dada la matriz de confusión

Tabla 5 Matriz de confusión para análisis de rendimiento en aprendizaje supervisado (Fawcett, 2006)

		Verdadero		
		Positivo	Negativo	
Test	Positivo	Verdadero Positivo	Falso Positivo Tipo I α	Total tests positivas
	Negativo	Falso Negativo Tipo II β	Verdadero Negativo	Total tests negativas
		Total Verdadero Positivo	Total Verdadero Negativo	

Si bien los métodos para comparar dos algoritmos de aprendizaje en un solo conjunto de datos ya se han examinado durante bastante tiempo, el tema de las pruebas estadísticas para las comparaciones de más algoritmos en conjuntos de datos múltiples, que es aún más esencial para los estudios típicos de aprendizaje automático, ha sido casi ignorado. En base a eso, se utilizará un

conjunto de pruebas no paramétricas simples, pero seguras y robustas para las comparaciones estadísticas de clasificadores: la prueba de rangos con signo de Wilcoxon para comparar dos clasificadores y la prueba de Friedman con las pruebas **post-hoc** correspondientes para comparar más clasificadores sobre múltiples conjuntos de datos. El análisis post-hoc se utiliza para probar la precisión, sensibilidad, y especificidad; para probar la significancia estadística mediante pruebas de permutación e identificar las características que proporcionan mayor contribución (Vieira et al., 2020). Los resultados de este último también se pueden presentar de forma ordenada con los **diagramas CD de diferencia crítica**. (Demšar J., 2006).

3.2. Diseño de la solución

Las BCI basadas en EEG de manera compacta y relevante, incluyen: Adquisición de datos, procesamiento previo de datos, extracción de patrones y técnicas de clasificación (Cao, 2020). Dado en términos generales de manera muy similar al flujo del Aprendizaje Automático (Mathworks, 2017; Vieira et al., 2019).

La IA está transformando todas las funciones comerciales y el desarrollo de software no es una excepción. Las técnicas de aprendizaje automático no solo se pueden utilizar para acelerar el ciclo de vida de desarrollo de software tradicional, sino que también presentan un paradigma completamente nuevo para inventar tecnología.(Yao, 2018). El Aprendizaje automático y el aprendizaje profundo cambian el modelo tradicional de desarrollo de software ya que hay muchas tareas y decisiones que son demasiado complejas para programar de manera explícita en las computadoras, por el contrario, con este nuevo paradigma se prepara los datos asociados al dominio del problema los cuales son provisionados a algoritmos de clasificación y aprendizaje que son entrenados de manera iterativa, El modelo tiene la capacidad de deducir los patrones y características de interés sin intermediación humana. En otras palabras, el código está en función del ajuste de los parámetros del modelo como los pesos de las redes neuronales, por ejemplo, en una red tipo back propagation o de gradientes descendentes. Por lo tanto, ajustar el modelo generara una alteración en su comportamiento, el cual funciona de manera distinta al tradicional modelo de desarrollo de software, como se describe en la Ilustración 40 (Arriba Izquierda).

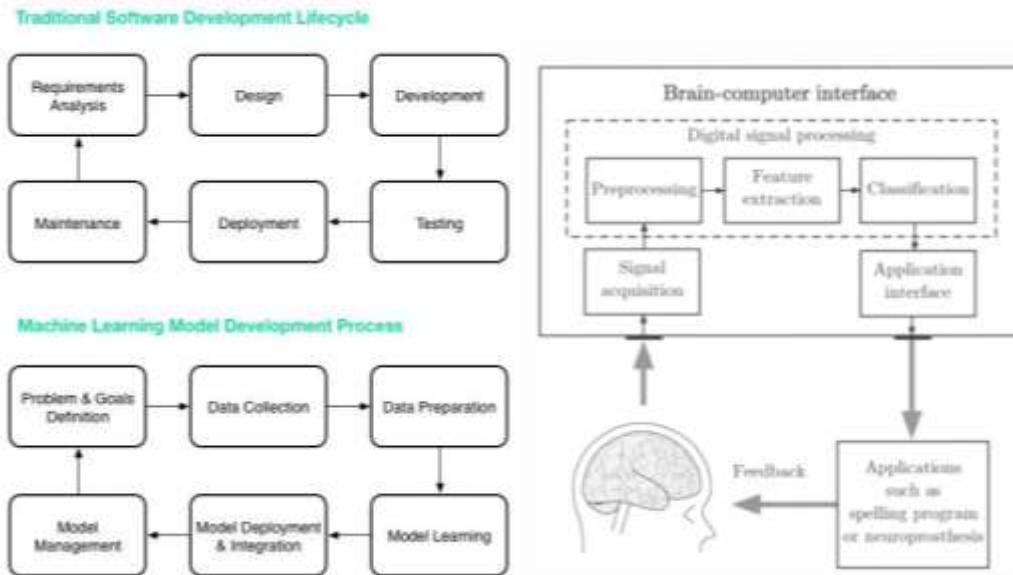


Ilustración 40 Comparativo de procesos de desarrollo para BCI y ML Izquierda: Comparativa entre el modelo de desarrollo de software tradicional y el Aprendizaje Automático(Yao, 2018). Derecha: Diagrama de bloques de una BCI(Sörnmo & Laguna, 2005) . Abajo Centro: Las 4 fases principales para aplicación de Aprendizaje Automático a nivel de BCI (Mathworks, 2017).

De manera análoga al proceso de aprendizaje automático, se implementan las fases para el desarrollo de interfaz cerebro computador BCI, como lo describe (Sörnmo & Laguna, 2005) en la Ilustración 40 (Arriba Derecha), se utiliza un procedimiento definido de manera esquemática en 4 fases. Partiendo desde la adquisición de datos (Sección 3.2.1), para posteriormente poder dar un tratamiento a la neuro señal adquirida utilizando técnicas de procesamiento de señales EEG mediante filtros y/o extracción de características (Sección 3.2.2), una vez la señal ha sido sometida a un proceso de preparación de datos, para ser pasada de la manera más limpia posible a fase de elaboración y ejecución de uno o varios modelos de clasificación (Sección 3.2.3) con los cuales se espera obtener una evaluación del rendimiento y de esta manera implementar, poner en “producción” e integrar todo el proceso sobre la BCI (Sección 3.2.4). En la mayoría de los casos este proceso se define de manera iterativa con la finalidad de mejora en el rendimiento de la interfaz a largo plazo. A la luz de dicha evidencia, podemos decir que es posible generalizar las fases del proceso de desarrollo de una BCI con el realizado para la implementación de un modelo de aprendizaje automático (Ilustración 40 Abajo).

3.2.1. Adquisición de datos

Recientemente en la literatura científica ha reportado data sets relacionadas con mente divagante(Groot et al., 2021), estado de meditación(Brandmeyer & Delorme, 2018) y estados de atención general (Aci et al., 2019) o conciencia plena. Que correlacionan a los estados mentales

relacionados con el Default Mode Network y la mente divagante, cabe resaltar que la mayoría de los experimentos se llevan a cabo con EEG de alta resolución, destacándose dispositivos de 32 y 64 canales como NEXXUS o Biosemi. Además de llevarse a cabo con otros aparatos de medidas electrofisiológicas como EOG o fMRI.

El repositorio que contiene la fuente tomada como referencia para el análisis de datos a nivel de EEG proviene de un estudio reciente donde se analizó la mente divagante en el contexto de la meditación basada en la respiración (Rodríguez-Larios & Alaerts, 2021). Las muestras fueron recolectadas de veintiocho sujetos (11 hombres, edad media 23,46 años, rango de edad: 20-29). Los formularios de consentimiento y el diseño del estudio fueron aprobados por el Comité de Ética Social (SMEC) de la Universidad de Lovaina, de acuerdo con la Declaración de Helsinki de la Asociación Médica Mundial. Se obtuvieron grabaciones de EEG mientras los participantes realizaban una tarea de concentración en la respiración. Se instruyó a los participantes para que se concentraran en la sensación de respirar mientras cerraban los ojos. A intervalos aleatorios (20-60 s), a los participantes se les presentó un sonido de campana y se les pidió que abrieran los ojos y respondieran un cuestionario.

(i) "¿Qué estabas haciendo justo antes de escuchar el sonido"? (dos opciones de respuesta: centrarse en la sensación de respirar o pensar en otra cosa)

(ii) "¿Qué tan seguro está de su respuesta"? (Escala Likert de 7 puntos; 1: nada seguro; 7: completamente seguro)? "¿Cómo te sentías antes de escuchar el sonido"? (Escala Likert de 5 puntos basada en la calificación de excitación de Manikin de autoevaluación; 1: excitado; 5: tranquilo; Bradley & Lang, 1994). Las instrucciones de la tarea y las preguntas se mostraron en la pantalla de la computadora frente a los participantes (programadas con el software E prime 2.0).

Antes del procedimiento experimental, los participantes realizaron una prueba de práctica. La tarea consistió en un total de 40 ensayos (duración total de aproximadamente 40 min). Adicionalmente se tomaron tests de excitación, valencia y somnolencia, los cuales solo estaban disponibles para 22 (de 25) participantes.

El sistema Nexus-32 (versión 2015a, Mind Media, Países Bajos) y el software BioTrace (Mind Media) se utilizaron para realizar grabaciones de electroencefalografía (EEG). El EEG se registró de manera continua, utilizando una malla de 22 electrodos (dos electrodos de referencia y un electrodo de tierra) colocada de acuerdo con el sistema 10-20 (MediFactory). Los movimientos oculares verticales (VEOG) y horizontales (HEOG) se registraron colocando electrodos de espuma pregelificada.

La señal de EEG se amplificó utilizando un amplificador unipolar con una frecuencia de muestreo de 512 Hz.

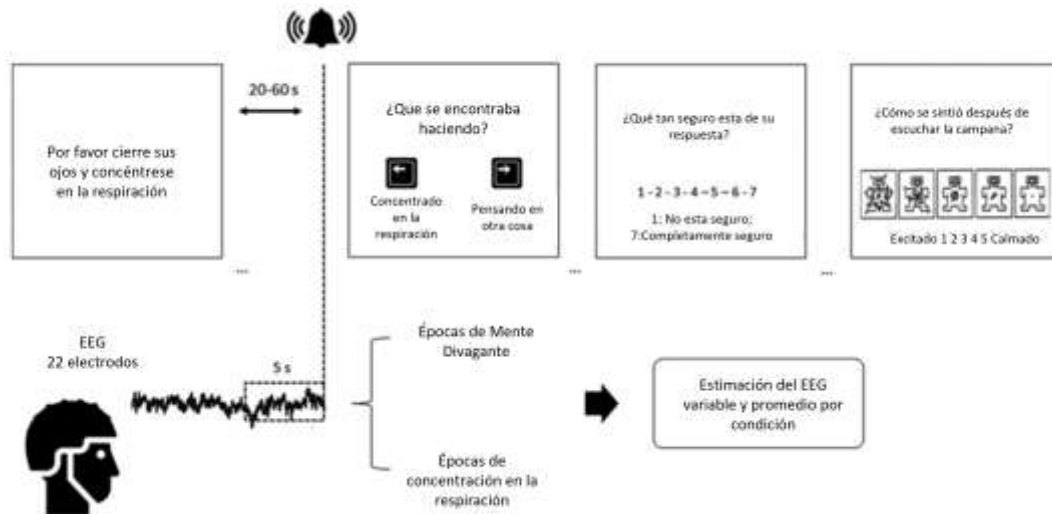


Ilustración 41 Diagrama del diseño experimental y enfoque analítico. Representación del diseño experimental y enfoque analítico. Se indicó a los participantes que se concentraran en su respiración mientras mantenían los ojos cerrados y que abrieran los ojos cada vez que escucharan el sonido de una campana. Después del sonido de la campana, los participantes tenían que informar si se estaban concentrando en su respiración o pensando en otra cosa usando el teclado de una computadora. También se incluyeron en cada ensayo preguntas adicionales que incluían autoevaluaciones de su nivel de confianza y excitación. Los participantes completaron 40 ensayos y la duración de cada ensayo varió entre 20 y 60 s. Solo los últimos 5 s antes del sonido de la campana se utilizaron para el análisis de EEG posterior. Estas épocas de EEG se clasificaron en condiciones de concentración de respiración (BF) o mente divagante (MW) según la respuesta posterior del participante (Rodríguez-Larios & Alaerts, 2021)

Es importante destacar que este experimento, se encuentra por fuera del alcance de los paradigmas más comúnmente utilizados para este tipo de pruebas como son tarea de atención sostenida a la respuesta (SART) y una tarea de búsqueda visual (Beninger et al., 2021; Y.-T. Chen et al., 2020b; Groot et al., 2021; Jin et al., 2019, 2020) y por el contrario esta soportado en meditación basada en la respiración y en una prueba por validación (Cuestionario), como el caso de (Kawashima & Kumano, 2017). Así mismo durante de la revisión de la literatura los repositorios y fuentes de datos EEG, se descubrió que se cuenta con una considerable diversidad de modalidades y protocolos de captura relacionados con estados mentales de mente divagante y meditación, de los que fueron descartadas: (Brandmeyer & Delorme, 2018; Dong et al., 2021; Grandchamp et al., 2014; Groot et al., 2021) . Teniendo en cuenta criterios como el enfoque frente al estado del arte, disponibilidad de los datos crudos, así como la pertinencia y validación del protocolo de captura para el objetivo de este trabajo en el contexto de mente divagante y meditación la fuente de datos escogida fue (Rodríguez-Larios & Alaerts, 2021)

3.2.2. Preprocesamiento y extracción de características

En la actualidad existe diversas librerías y repositorios para el análisis de datos EEG a nivel de preprocesamiento y extracción de características, previas a la etapa de clasificación, entre las cuales se destacan en este trabajo de investigación: PyEEG (Bao et al., 2011), MNE (Gramfort, 2013), SciPy (The SciPy community, 2021), MEEGKIT (Barascud Nicolas, 2021) o pyRiemann (Barachant et al., 2012, 2013).

También se destacan otras librerías consideradas dentro del espectro de implementación de algoritmos de análisis EEG para clasificación de mente divagante como, EEGLAB (Delorme & Makeig, 2004; Kothe, 2012) que comprende una caja de herramientas y una interfaz gráfica de usuario,

EEGLAB, se ejecuta en el entorno MATLAB para procesar colecciones de datos de EEG de prueba única y / o promediados de cualquier número de canales. Las funciones disponibles incluyen datos de EEG, importación de información de canales y eventos, visualización de datos (desplazamiento, mapa del cuero cabelludo y trazado del modelo de dipolo, además de trazados de imágenes ERP de múltiples pruebas), preprocesamiento (incluido el filtro de artefactos, filtrado, selección de época y promediado), análisis de componentes independiente (ICA) y descomposiciones de tiempo / frecuencia, incluida la coherencia cruzada de canales y componentes, respaldada por métodos estadísticos basados en el re muestreo de datos .

Así mismo eeglib (Cabañero et al., 2019) Es una biblioteca en Python que proporciona herramientas para analizar señales de electroencefalografía (EEG). Esta biblioteca es principalmente una herramienta de extracción de características que incluye muchos algoritmos de uso frecuente en el procesamiento de EEG con el uso de un enfoque de ventana deslizante. eeglib proporciona una interfaz amigable que permite a los científicos de datos que trabajan con señales de EEG extraer muchas características con solo unas pocas líneas. Trabajos de este tipo permiten corroborar que las técnicas nominadas dentro de esta investigación son idóneas para el procesamiento de las señales EEG, ya que se encuentran dentro del estado de arte para el preprocesamiento y extracción de características en neuro señales como Dimensión fractal petrosiana o Dimensión Fractal Higuchi, además de ofrecer técnicas de amplio uso como parámetros Hjorth, fluctuación de análisis en decremento, coeficiente de relación cruzada o FFT.

Algunas de las técnicas estudiadas en el diseño de la fase de preprocesamiento para la clasificación de mente divagante son: EL uso de scripts MATLAB personalizados y funciones EEGLAB, usando **filtros entre 1 y 40 Hz**, Eliminación de ruido abrupto en los datos mediante el método de reconstrucción del subespacio de artefactos **ASR**, referenciar a los electrodos promedio, realizar **segmentación** en época de -5s en relación con las sondas de sonido de campana y excluir las épocas con amplitudes absolutas superiores a 100 μ V, Para el caso del set de datos utilizado en este proyecto de investigación (Rodríguez-Larios & Alaerts, 2021). Además de aplicar transformada rápida de Fourier **FFT** a corto plazo. Se **promediaron las amplitudes** absolutas (μ V) y relativas (% de la potencia total) a lo largo de las épocas de 5 s por sujeto y electrodo. Finalmente, las épocas limpias de datos de EEG se clasificaron en las categorías de enfoque en la respiración (BF) o mente divagante (MW) según las respuestas posteriores del sujeto.

Otra estrategia de preprocesamiento (Jin et al., 2020) que se tuvo a consideración dentro del diseño de la fase de extracción de características, es el realizado mediante **análisis offline**, comenzando por la eliminación de picos excesivos u obviamente más ruidosos, para los canales defectuosos, reemplazados mediante interpolación esférica basada en los electrodos vecinos. Los **filtro de paso de banda** (0,1 a 42 Hz), corrección de línea base, así como inspección visual previo a la fase de **ICA** para detectar artefactos oculares. Se tienen en cuenta técnicas de procesamiento basado en **potencial evocado ERP (P1, N1, P3)**, así como en el análisis de la frecuencia. (Jin et al., 2019; Tasika et al., 2020). De manera análoga se aplican filtros, ICA con remoción de artefactos y ERP de naturaleza similar en (Brandmeyer & Delorme, 2018). Apegados a esta misma estructura de técnicas de filtros paso bajo y altos, además de ICA se realiza en (Groot et al., 2021)

Otras técnicas de preprocesado utilizan metodologías basadas en estadística como el **coeficiente de correlación de Pearson** (Kawashima & Kumano, 2017).

3.2.3. Clasificación: Desarrollar un modelo predictivo

En la revisión sistemática obtenida de comparar los diferentes algoritmos de Machine Learning se ha evidenciado el uso de electroencefalografía para el análisis de distintos fenómenos asociados al funcionamiento del cerebro, mediante la aplicación de técnicas de **minería de datos**(Witten et al., 2011), el aprendizaje automático y estadística (Hastie et al., 2009), por otro lado, han enriquecido el descubrimiento de información a partir de los datos generados por las señales EEG, y han sido de considerable importancia en la ayuda de diagnósticos asociados a patologías cerebrales. Se destacan casos como la aplicación de la Inteligencia Computacional mediante redes neuronales en la clasificación de electroencefalografías (Jia, 2011), la clasificación de EEG usando redes neuronales y utilizando **regresión logística** en casos de epilepsia (Subasi & Erçelebi, 2005), utilizando **k-means** para agrupar las bandas de frecuencia EEG, haciendo uso de las redes neuronales **perceptrón multicapa** (MLPNN) como modelo de clasificación, en un mecanismo de soporte de decisiones diagnósticas en el tratamiento de epilepsia (Orhan et al., 2011), estudios del sueño (Prerau et al., 2017). Estudios similares resaltan el uso de minería de datos en datos EEG para el diagnóstico de depresión, utilizando **árboles** y **algoritmos genéticos** (Mohammadi et al., 2015). Existen técnicas de aprendizaje automático que han demostrado realizar un aporte a las clasificación de señales EEG, como es el caso de diagnósticos de trastornos mentales mediante el uso de métodos adaptativos, como la distancia ponderada del vecino más cercano **KNN** (weighted distance nearest neighbor **WDNN**) (Parvinnia et al., 2014), clasificación de las características no lineales en desorden de hiperactividad y déficit de atención, utilizando KNN (Ghassemi et al., 2012), clasificación de los patrones de epilepsia a través de EEG con KNN(Bhuvaneswari & Kumar, 2015) , se han usado máquinas de soporte vectorial **SVM** para discriminar artefactos en las grabaciones EEG (Lawhern et al., 2012), clasificación usando redes neuronales y redes **bayesianas** para mejorar el rendimiento de dispositivos biomédicos basados en EEG, EMG (Rechy-Ramirez & Hu, 2015), redes neuronales con análisis Wavelet en la detección de desórdenes epilépticos (Zainuddin et al., 2012),(Dehuri et al., 2013) y Alzheimer(McBride et al., 2015), el uso de redes neuronales tipo perceptrón multicapa, en la clasificación de estados emocionales para sistemas de computación afectiva basados en EEG (Othman et al., 2013; Shams et al., 2013),(Lahane & Sangaiah, 2015), inclusive categorizar la susceptibilidad a la hipnosis utilizando vecino más cercano NN y Fuzzy NN - FNN (Elahi et al., 2013). Producto de dichos estudios, se ha evidenciado un creciente interés en el uso y desarrollo de herramientas informáticas apoyadas en inteligencia computacional para el enriquecimiento del análisis de datos cerebrales, entre ellas PyMVPA (Hanke et al., 2009) o PyEEG (Bao et al., 2011).

En el caso de clasificación de estados mentales relacionados con mente divagante en (Rodriguez-Larios & Alaerts, 2021) se utilizó una estrategia basada en búsqueda de picos espectrales Alpha y Theta en las señales comparando estado mental divagación mental con estado de concentración en la respiración (meditación), mediante análisis y validación estadística con proporciones de **relaciones de frecuencia cruzada** y como segundo enfoque se usó frecuencias instantáneas, **basado en valores de sincronía**.

Otros trabajos se encargan de investigar si el estado mental divagante depende completamente de la vigilancia y las demandas de la tarea actual, o si es un fenómeno independiente. Con este fin, se utilizan **clasificadores con máquinas de soporte vectorial (SVM)** en datos de EEG en condiciones de baja y alta vigilancia, así como en condiciones de baja y alta demanda de tareas (Jin et al., 2020). Este estudio demuestra el valor de los clasificadores de aprendizaje automático para revelar patrones en datos neuronales y descubrir las estructuras neuronales asociadas combinándolas con

técnicas clásicas de análisis de EEG. Se aplica kernel de función de base radial (**RBF**) durante el entrenamiento para aprovechar la potencia no lineal de la SVM. Se determina que se utilizara un clasificador de máquina de vectores de soporte (SVM) debido a su excelente desempeño en la clasificación de EEG en estudios previos de mente divagante (Jin C, 2021; Jin et al., 2019, 2020; Kawashima & Kumano, 2017) Una razón importante para usar un SVM es que este clasificador no requiere una relación lineal entre las características, lo cual es una ventaja en la clasificación cuando no podemos hacer una suposición específica sobre la forma del patrón de interacción entre las características.

Así mismo se han adelantado estudios que sirven como referencia en el diseño y selección de los algoritmos de este proyecto, como el uso de diversas técnicas de clasificación aplicadas al set de datos con el fin determinar la mejor arquitectura. Es el caso de **Soporte de máquinas vectoriales, bosque aleatorio y perceptrones multicapa** para detección de mente divagante en conductores de automóviles, en estudios a nivel de EOG e inclusive ya previamente utilizados en estudios de meditación y mente divagante (Beninger et al., 2021; Grandchamp et al., 2014; Groot et al., 2021; Kawashima & Kumano, 2017; Tasika et al., 2020). Las máquinas de soporte vectorial basadas en **funciones de regresión lineal** también son utilizadas en modelos de clasificación como en (Kawashima & Kumano, 2017).

Uno de los enfoques más innovadores para la tipología de clasificación de este proyecto está basado **Deep Learning** donde un modelo de **red neuronal convolucional profunda (CNN)** por canal se utiliza para clasificar las características del estado concentración y mente divagante extraídos directamente de las señales de EEG. Llama la atención que este modelo recae solamente en el análisis de los datos y cuenta con un rendimiento sobresaliente por encima del 90% para precisión, sensibilidad y especificidad. (Hosseini & Guo, 2019). Siendo el primer estudio que emplea CNN para la detección automática de MW basado en datos de EEG y al igual que muchos modelos de clasificación para interrupción de la concentración y mente divagante la arquitectura del modelo fue elegida por ensayo y error.

Al igual que en la etapa de preprocesamiento metodologías de clasificación estadísticas pueden aplicarse para la caracterización de divagación mental, como **estadística paramétrica** para resultados de comportamiento utilizando la prueba t pareada, la prueba t no pareada con estimaciones de varianza no agrupadas y regresión lineal. (Brandmeyer & Delorme, 2018). Para los datos de EEG, las estadísticas se realizaron en **mapas topográficos** y de **tiempo - frecuencia** utilizando estadísticas de dos colas emparejadas o no emparejadas. Para los datos de EEG, la corrección para comparaciones múltiples se realizó utilizando el método de agrupamiento o clustering. Se usó la Tasa de Descubrimiento Falso para corregir las comparaciones múltiples y obtuvimos resultados similares en comparación con el método de agrupamiento.

Para la clasificación de EEG en el contexto de la meditación y la interrupción de la concentración, las técnicas supervisadas juegan un papel importante, como (Groot et al., 2021; Jin et al., 2020). usando máquina de vectores de soporte no lineal (**SVM**) con funciones de base radial (**RBF**) como núcleo para clasificar ensayos individuales en estados de atención en tarea o fuera de tarea con scikit-learn.svm. Consolidando a **Scikit-learn**(Pedregosa et al., 2011). Como una de las más opcionadas para la implementación de los algoritmos de clasificación, no solo por su sencillez sino también por la facilidad de integración con otras librerías de EEG mediante las funciones “fit” y “transform” y la facilidad para estructurar pipelines de análisis de datos.

De acuerdo con los diversos estudios relevados en (Lotte et al., 2018a), se siguen las pautas para elegir los métodos de clasificación apropiados para el diseño BCI.

3.2.4. Validación, optimizar del modelo y despliegue

Para el diseño de la fase de validación se tuvieron en cuenta los distintos métodos utilizados a lo largo de la revisión de la literatura para clasificación de mente divagante MW. Por ejemplo, en (Rodríguez-Larios & Alaerts, 2021). Aplica Manejo de datos y análisis estadístico en donde se promediaron los cuestionarios específicos del ensayo sobre la excitación y la confianza obtenidas durante la tarea entre los ensayos de la condición BF y MW (por sujeto) y se utilizaron pruebas t de muestras pareadas para evaluar las diferencias relacionadas con cada una de las condiciones. Se realizaron análisis de **correlación de Pearson** para evaluar la relación entre la variabilidad interindividual en la proporción de épocas de donde hubo presencia de mente divagante (%) y los informes generales del nivel de somnolencia, excitación y valencia emocional de los participantes. A nivel de Electroencefalograma se partió desde un enfoque basado en variables dependientes de EEG Se adoptó un **método estadístico de permutación basado en clústeres** para evaluar las diferencias relacionadas con la condición (entre MW y BF). Este método estadístico controla la tasa de **error de tipo I** que surge de comparaciones múltiples a través de una aleatorización de **Montecarlo no paramétrica**. los datos se barajaron (1000 permutaciones) para estimar una distribución "nula" de los tamaños del efecto en función de las estadísticas a nivel de conglomerado. El **valor de p** corregido por conglomerados se definió como la proporción de particiones aleatorias en la distribución nula para las cuales las pruebas estadísticas excedieron la obtenida para cada conglomerado significativo en los datos originales (no mezclados). El nivel de **significancia** para la prueba de permutación de conglomerados se estableció en 0.025 (correspondiente a una tasa de falsas alarmas de 0.05 en una prueba de dos clases). El nivel de significancia para la prueba de **permutación de conglomerados** se estableció en 0.025 ". "Para evaluar las diferencias relacionadas con la condición, se eligió la **prueba t** de muestras pareadas como prueba estadística. Además, se realizaron ANCOVA unidireccionales de medidas repetidas en los grupos significativos identificados (promediados dentro de los grupos positivos y negativos por separado) de cada variable dependiente de EEG para evaluar si el efecto de la condición (MW- BF) fue significativamente influenciado por los niveles de somnolencia (informados a través de informes al final de la tarea. Los datos se graficaron utilizando scripts MATLAB personalizados en combinación con EEGLAB ".

Algunos de los enfoques más utilizados para la validación son los **esquemas de validación cruzada** (CV) entre ellos el de 10 veces, validación cruzada de salida de un participante (LOPOCV) y de manera extraordinaria un esquema RFE (Rich Features Embedding) (Groot et al., 2021) y los cuales se encuentran ilustrados en trabajos como (Beninger et al., 2021; Jin et al., 2020; Kawashima & Kumano, 2017), además se calculó la **precisión** individual y se realizó una comparación a nivel de grupo dentro de cada categorización utilizando pruebas t pareadas. Siendo precisión y **exactitud** las métricas de desempeño más comunes (Aci et al., 2019; Beninger et al., 2021; Grandchamp et al., 2014; Groot et al., 2021; Jin et al., 2019, 2020; Kawashima & Kumano, 2017; Tasika et al., 2020). Dada la naturaleza desbalanceada de los data sets recolectados en la mayoría de las pruebas, se utilizan métodos como validación cruzada de dejar uno fuera (LOOCV). LOOCV es un método de validación que, en cada ciclo de entrenamiento, se deja para probar un caso de la muestra de datos completa mientras que el resto de los casos forman la muestra de entrenamiento.(Jin et al., 2019). Otros estudios comparan la precisión predictiva de varios clasificadores con la respuesta más común en el subconjunto de datos que se están considerando(Beninger et al., 2021). En el caso de

clasificación de distracción mental, se sugiere tomar medidas de exactitud predictiva, precisión y sensibilidad para cada algoritmo. Además de **la precisión predictiva, la media y la desviación estándar, se sugiere el cálculo de los valores de la tasa de verdaderos positivos, la tasa de falsos positivos, la tasa de verdaderos negativos, la tasa de falsos negativos, la precisión, la exhaustividad y la especificidad.** (Beninger et al., 2021; Groot et al., 2021).

Una novedosa técnica de validación basada en la banda de frecuencia espectral con incidencia de los pensamientos divagantes es presentada en (Brandmeyer & Delorme, 2018) con gráficos de perturbación espectral relacionada con eventos (**ERSP**) y **gráficos diferenciales** de importancia en la actividad de las bandas theta (4-7Hz) y alfa (9-11Hz) para practicantes de meditación expertos.

4. CAPITULO 4. Análisis de Resultados

Con base en la metodología propuesta en el capítulo 3, en este capítulo se busca estimar y comparar los desempeños en F1-score para los diferentes métodos computacionales de discriminación de BF y MW que se pueden construir dependiendo del clasificador final elegido, a saber, Regresión Logística (LR), Análisis Discriminante Lineal (LDA), Máquina de Vectores de Soporte Lineal (SVM) y Perceptrón Multicapa, sobre cuatro tipo de características excluyentes: Espacio Tangente (TSpace), Varianza Logarítmica (LogVar), Información de Fisher (FInfo) y Dimensión Fractal Petrosiana (PFD). Adicionalmente, dado que la señal EEG puede ser filtrada en frecuencia, se propone estudiar el efecto que en desempeño puede producir un rango de frecuencias específicos, para este caso se propone mediante un filtro IIR tipo Butterworth de 4 orden filtrar dos tipos de rango de frecuencias: de 1-40Hz (básicamente para incluir casi todo el espectro EEG), y de 4-14Hz para incluir las componentes alfa y beta de las señales EEG, asociada, en otros estudios (Rodríguez-Larios & Alaerts, 2021), a la discriminación espectral-estadística entre BF y MW.

Por otro lado, dado que las características de las señales EEG asociadas a BF y MW dependen de cada sujeto experimental, en este trabajo se proponen dos tipos de estudios para estimar y comprar el desempeño: entre-sujetos e intra-sujetos. En el primer caso se estudia el desempeño obtenido para el dataset de señales EEG que produce cada uno de los sujetos experimentales, estudiándose varias metodologías computacionales para discriminación de BF y MW sobre varios datasets (24 en total). En el segundo caso se unen todos los datasets para crear uno solo, generándose así un estudio de varias metodologías computacionales para discriminación de BF y MW sobre 1 solo dataset.

4.1. Estudio Entre-sujetos:

Debido a las condiciones del experimento que permitió recoger las señales EEG asociadas a BF y MW se logró determinar que por sujeto se tiene un número variado de épocas para cada una de estas clases. En la Ilustración 42 se muestra los valores exactos para cada uno de los sujetos. Debido al desbalance de los datos se obtiene el F1-score ponderado en un esquema de validación cruzada estratificada de 10 divisiones repetido 3 veces. Como resultado en la Ilustración 43 se muestra los desempeños promedios con sus respectivas desviaciones estándar para cada par clasificador/característica en cuatro configuraciones diferentes determinadas por el número de canales y los rangos de frecuencia descritos anteriormente.

1	BF	31	7	BF	25	13	BF	28	19	BF	19
	MW	9		MW	15		MW	12		MW	21
2	BF	12	8	BF	16	14	BF	32	20	BF	21
	MW	28		MW	24		MW	8		MW	19
3	BF	29	9	BF	29	15	BF	21	21	BF	14
	MW	11		MW	11		MW	19		MW	26
4	BF	27	10	BF	29	16	BF	18	22	BF	26
	MW	13		MW	11		MW	22		MW	14
5	BF	33	11	BF	29	17	BF	17	23	BF	27
	MW	7		MW	11		MW	23		MW	13
6	BF	3	12	BF	14	18	BF	17	24	BF	15
	MW	37		MW	26		MW	23		MW	25

Ilustración 42. Número de épocas EEG asociadas a BF y MW para cada uno de los sujetos experimentales.

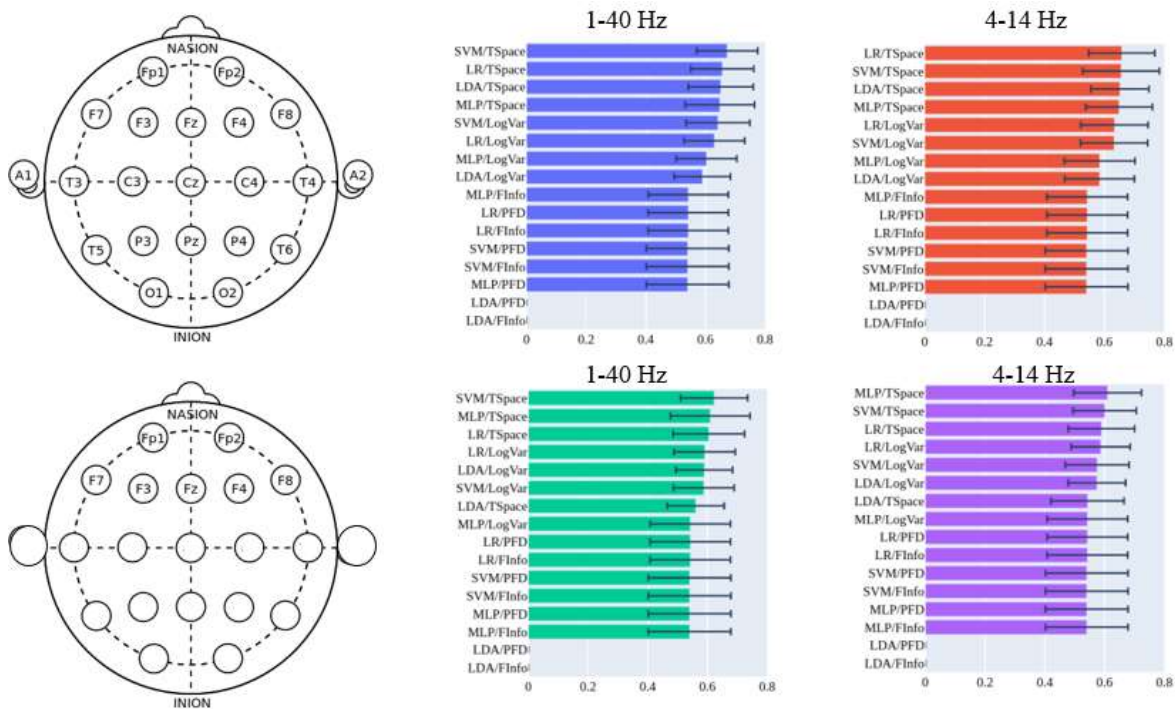


Ilustración 43. Valores promedio de desempeño sobre los sujetos por cada uno de los pares clasificador/característica en 4 configuraciones determinados por el número de canales y rangos de frecuencia.

La Ilustración 43 permite evidenciar que en promedio los clasificadores que se apoyan en características como TSpace y LogVar se desempeñan mejor en las cuatros configuraciones. Al respecto, si se seleccionan únicamente métodos computacionales que no se apoyan ni en FInfo ni en PFD se pueden comparar en términos estadísticos los diferentes pares clasificadores/característica sobre los múltiples datasets (por usuario) utilizando los diagramas críticos de diferencia descritos en 3.1.4 para evidenciar las posibles diferencias estadísticas entre los modelos que mejor desempeñaron en cada una de las configuraciones propuestas.

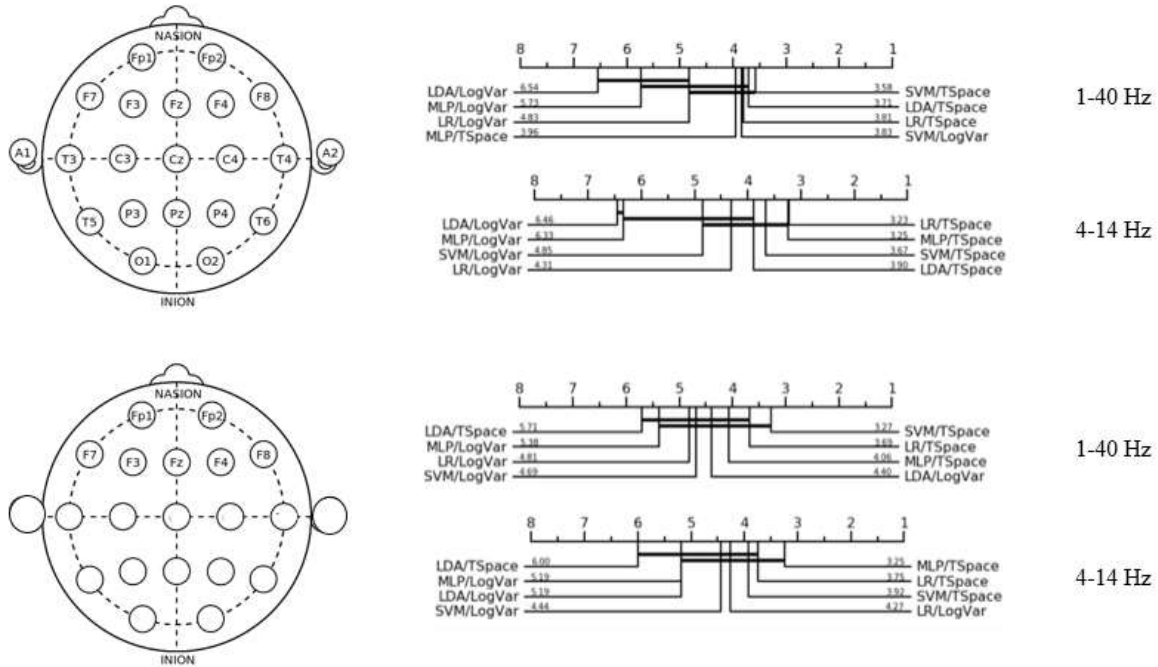


Ilustración 44. Diagramas críticos de diferencia entre los pares clasificador/característica que mejor desempeño promedio obtuvieron en cada una de las cuatro configuraciones.

La Ilustración 44 evidencia que los modelos SVM/TSpace y LR/TSpace se encuentran entre los tres mejores modelos en las cuatro configuraciones propuestas y que poseen diferencias estadísticas con otro modelos sin embargo entre estos, dicha diferencia no es significativa en términos estadísticos. Es importante mencionar que tanto SVM lineal como la regresión logística son clasificadores interpretables que permitirían determinar la preponderancia de la información temporal y espacial que aporta cada canal para discriminar BF y MW.

4.2. Estudio Intra-sujetos:

Al integrar en un solo dataset las épocas de BF y MW aportada por todos los sujetos experimentales se compilan los valores totales reportados en la Tabla 6.

Tabla 6. Valores totales de sujetos, épocas de señales EEG de 5 segundos para BF y MW.

Total Sujetos	# Épocas BF	# Épocas MW
24	532	428

Claramente se presenta una situación de dataset desbalanceado por clases. Por esta razón se obtiene el F1-score ponderado en un esquema de validación cruzada estratificada de 10 divisiones repetido 3 veces. Al realizar esto para cada uno de los pares clasificadores/características en los dos tipos de rangos de frecuencia para las dos configuraciones de canales, en la Ilustración 44 se recopilan en forma ranqueada los desempeños promedios obtenidos de F1-score con su correspondiente desviación estándar en forma de gráfico de barras y errores.

A partir de esta figura se evidencia varios puntos. Primero, en cualquier configuración de rango de frecuencia y número de canales, las características TSpace y LogVar permiten desarrollar capacidad discriminante con cualquiera de los clasificadores con un desempeño promedio superior a 0.55 en el F1-Score ponderado. Esto sugiere que este par de características puede representar la información asociada a BF y MW que permita su discriminación mediante una técnica de aprendizaje automática como las consideradas en este trabajo. En particular, el ranking permite evidenciar que la Regresión Logística y la SVM lineal serían los mejores candidatos como clasificadores para estas características. Segundo, los pares clasificador/característica que mejor desempeñaron en promedio, superaron la línea del 0.6 en el F1-score cuando se utilizaron 21 canales que cuando se utilizaron únicamente los 7 canales frontales. Esto indica que parte de información discriminante de BF y MW se está distribuyendo en los canales centrales, parietales y occipitales además de los frontales. Tercero, en promedio, en ninguno de los pares modelos/característica que utilizaron FInfo y PFD se logró superar la línea del 0.4 en F1-score ponderado. Llama la atención que estas características están generando prácticamente el mismo comportamiento promedio independiente del número de canales y del rango de frecuencias. Se sugiere que a futuro se realice un estudio más profundo basado en técnicas de interpretabilidad que permita evidenciar si este es un comportamiento global o meramente local en el espacio característico.

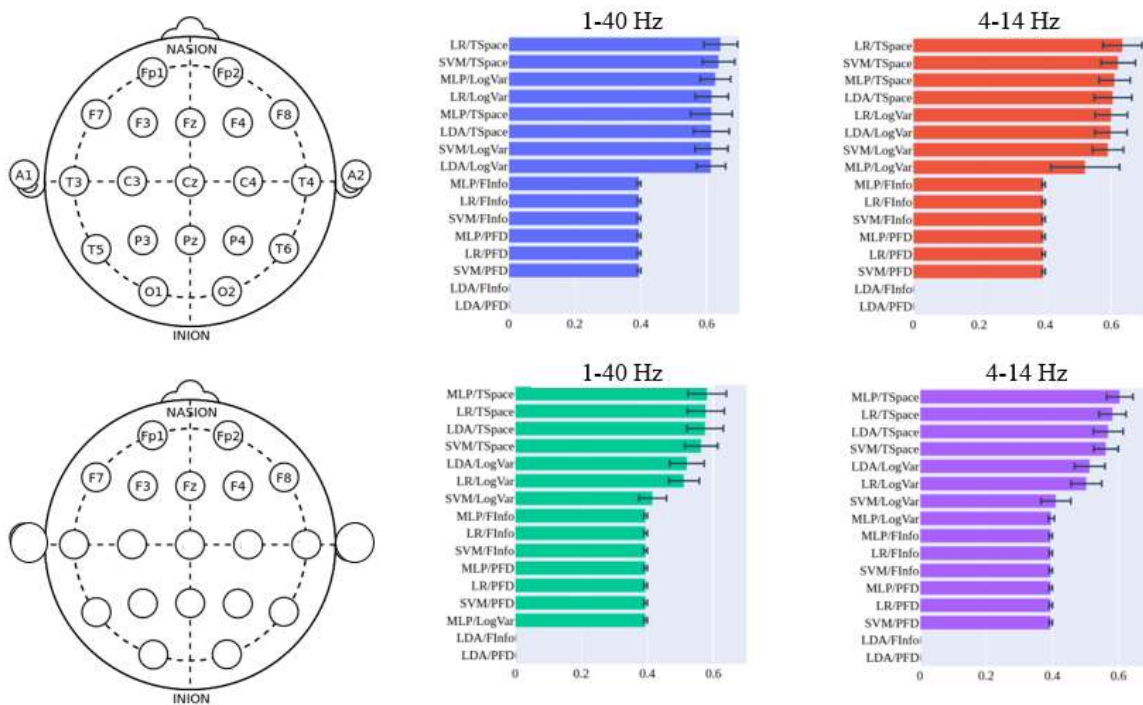


Ilustración 45. Ranking de desempeño para los diferentes modelos y características en la clasificación de BF y MW . En las gráficas de arriba se trabajó con todos los canales disponibles en el dataset original y en las abajo se trabajó únicamente con canales frontales.

Una inquietud surge naturalmente de los pares clasificador/característica que superaron la línea de 0.55 en F1-score ponderado: ¿las diferencias en promedio de desempeño entre estos pares son estadísticamente significativas? Para responder esto y dado que no se puede hacer ninguna asunción de distribución de probabilidad asociada a las muestras de la variable de desempeño

elegida en este trabajo, se utiliza una prueba no-paramétrica tipo Kruskal-Wallis para el análisis de las varianzas. Dicha prueba arroja los siguientes resultados para cada una de las configuraciones por canales y rango s de frecuencia:

Tabla 7. Estadístico y p-valor de la prueba Kruskal-Wallis para cada una de las configuraciones en número de canales y rango de frecuencias.

#	Configuración	Estadístico de la prueba	p-valor
1	21 canales (1-40 Hz)	12.21	0.094
2	21 canales (4-14 Hz)	26.94	0.00034
3	7 canales (1-40 Hz)	42.46	4.75e-08
4	7 canales (4-14 Hz)	77.28	3.11e-15

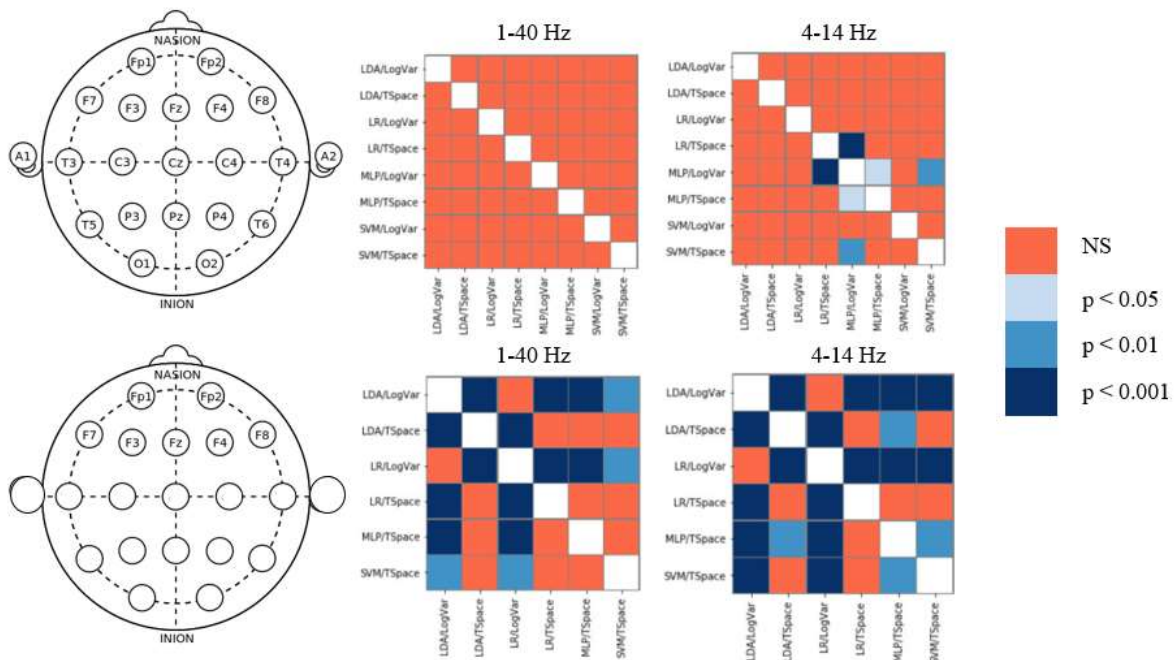


Ilustración 46. Mapas post-hoc para evaluación de la diferencia estadística significativa entre los valores promedios de desempeño de los modelos/características que superaron el umbral de 0.5 en el F1-score. NS se interpreta como: no hay evidencia suficiente en favor que haya diferencia estadística significativa.

Utilizando un nivel de significancia de 0.05 se puede interpretar que, para todos los casos, excepto para la configuración de 21 canales (1-40Hz), el p-valor está por debajo de dicho nivel, indicando que se ha generado evidencia estadística para rechazar la hipótesis nula de que los valores promedios poblacionales de los desempeños en los pares clasificador/característica sean iguales. Para averiguar cuales pares clasificador/característica se diferenciaron entre sí para la métrica de desempeño adoptada en este trabajo, se complementa el estudio anterior mediante un análisis post-hoc utilizando la prueba de Conover, corregida para múltiples hipótesis mediante Holm-Bonferroni. En la Ilustración 45, en forma de mapas post-hoc se muestran los resultados de esta última prueba utilizando únicamente los pares clasificador/característica que superaron la línea del 0.55 en el F1-score ponderado.

El mapa post-hoc de la configuración 1 evidencia el resultado obtenido en la prueba de Kruskal-Wallis, a saber, no hay evidencia en favor de la existencia de una diferencia estadística en los promedios de desempeños de los pares clasificador/característica entre sí. Por otra parte, el mapa post-hoc de la segunda configuración evidencia que la diferencia estadística significativa se presenta entre LR/TSpace y MLP/LogVar, seguida de SVM/TSpace y MLP/LogVar, y MLP/TSpace y MLP/LogVar. De hecho, los pares clasificadores/características LR/TSpace, SVM/TSpace y MLP/TSpace son los que mejores se desempeñaron en esta configuración de canales y de rango de frecuencia, ver Ilustración 44. Sin embargo, entre estos tres pares por ahora no existe evidencia de diferencia estadística significativa. Finalmente, en los mapas post-hoc de las configuraciones 3 y 4 se evidencia varias diferencias estadísticas significativas entre pares clasificador/característica.

Es importante mencionar que todos los resultados obtenidos hasta ahora se obtuvieron con hiper-parámetros (parámetros definidos por usuario) por defecto en todos los clasificadores. No se aplicó ninguna estrategia de búsqueda de hiper-parámetros ni de regularización, algo que a futuro merece un estudio más profundo para determinar si la sintonización de estos hiper-parámetros permite mejorar significativamente en términos estadísticos el promedio de desempeño en la métrica F1-score.

5. CAPÍTULO 5. TRABAJO FUTURO, CONCLUSIONES Y RECOMENDACIONES

5.1. Diseñar un modelo e implementar un prototipo computacional, para la detección de estado de mente divagante, que contribuya en el aprendizaje de la meditación.

Basado en el estado del arte de los distintos enfoques para la clasificación de la divagación mental mediante EEG (Beninger et al., 2021; Brandmeyer & Delorme, 2018; Dong et al., 2021; Groot et al., 2021; Hosseini & Guo, 2019; Jin et al., 2019; Kawashima & Kumano, 2017; Rodriguez-Larios & Alaerts, 2021; Tasika et al., 2020) se identifican 3 metodologías principalmente que se involucran en los análisis de los datos: El procesamiento puro de señales EEG, pasando por análisis estadísticos, hasta llegar a técnicas como la IA y ML incluyendo una combinación de las anteriores. Se puede concluir que el enfoque presentado en este trabajo basado, en un procesamiento y limpieza de la señal EEG, previo a la fase de clasificación y entrenamiento, así como el análisis estadístico posterior entre e intra sujetos, aborda de manera específica el problema de investigación relacionado con caracterizar el uso y la evaluación de técnicas de aprendizaje automático, para la clasificación de mente divagante en lecturas EEG. Así como proponer una serie de algoritmos basados procesamiento offline o fuera de línea, que pueden ser candidatos para trabajos futuros relacionados con mecanismos de neurofeedback durante el procesamiento online en el monitoreo vía EEG de estados mentales relacionados con la mente divagante y su incidencia en la meditación.

5.2. Establecer los datos provenientes de análisis neuronales con el fin de proyectar experimentos para la detección del Default Mode Network (DMN).

Los protocolos de captura de señales EEG para clasificación de la mente divagante MW, estado mental expresado a nivel neurofisiológico por el DMN. Deben ser soportados desde las bases de un adecuado diseño experimental, estadístico, electrofisiológico y neuro clínico. De esta manera la señal EEG obtenida será menos propensa al sesgo durante la siguiente fase de clasificación. Repositorios como OSF y Openeuro posibilitan la disponibilidad de datos que atienden a procedimientos avalados científicamente, ya que, dada la profundidad de estos, se requerirían recursos de difícil acceso en el ámbito local de la investigación en neurociencia, como aparatos EEG de alta resolución o software especializado de captura. Los datos crudos ofrecidos en (Rodriguez-Larios & Alaerts, 2021) se aceptan dado la idoneidad y compatibilidad de este protocolo de captura respecto a la relación de la mente divagante con la meditación centrada en la respiración; que a su vez conforman los objetivos de este proyecto. Estudios como los de (Brandmeyer & Delorme, 2018) avalan una reducción significativa de la activación del DMN durante la práctica de la meditación.

5.3. Evaluar las técnicas de procesamiento de neuroseñales EEG para la detección de DMN a través de dispositivos BCI.

Las señales EEG se caracterizan por ser estocásticas, no determinísticas, propensas a ruido y no estacionarias. Siendo necesario la aplicación de técnicas robustas como las basadas en geometría de Riemann. A la luz de este hecho, la caracterización espectral con técnicas como espacio tangente, ha demostrado tener un desempeño estadístico sobresaliente en la clasificación de neuro señales para mente divagante, respecto a las demás opciones empleadas en este análisis. La metodología de remoción de artefactos basados en análisis offline, dada la estructura de su algoritmo podría ser utilizada en aplicaciones online alimentadas por neurofeedback.

5.4. Determinar y aplicar técnicas de análisis de datos a partir de técnicas de clasificación y aprendizaje automático que aproximen la caracterización de mente divagante.

A partir de los resultados de las métricas de desempeño para la ejecución de los 4 pipelines propuestos en este trabajo, se concluye que las metodologías computacionales que podrían ofrecer un mejor rendimiento con clasificación de mente divagante MW contra concentración en la respiración BF son: Regresión Lineal – Espacio Tangente y SVM-Espacio Tangente. Esta última técnica de aprendizaje automático (SVM) corrobora su idoneidad como ya lo validaban trabajos previos relacionados con mente divagante (Beninger et al., 2021; Grandchamp et al., 2014; Groot et al., 2021; Kawashima & Kumano, 2017; Tasika et al., 2020).

5.5. Validar el prototipo del sistema mediante pruebas que se llevaran a cabo sobre la interfaz.

Dado que la naturaleza de los datos EEG obtenidos en (Rodriguez-Larios & Alaerts, 2021) tiende a ser desbalanceada, la validación estadística mediante validación cruzada repetida estratificada y la evaluación del desempeño basada en F1 score para pruebas intra-sujeto e inter-sujeto, se proyecta como una evidencia estadística que cuenta con mejor criterio discriminante que las técnicas tradicionales basadas en la precisión y en el cálculo de la desviación estándar de la precisión en la clasificación de estados mentales relacionados con divagación mental basado en EEG (Beninger et al., 2021; Grandchamp et al., 2014; Groot et al., 2021; Jin et al., 2020). Y si bien esta validación depende en cierta medida del protocolo de captura utilizado respecto a la naturaleza de los datos. Es importante destacar la validación estadística utilizada en la fuente de datos de esta investigación, basada en los resultados del cuestionario de excitación y confianza donde se calculó el promedio de las pruebas realizadas con MW y BF y después se utilizaron pruebas t pareadas para evaluar las diferencias con cada condición; además de análisis de correlación de Pearson para evaluar la variabilidad interindividual en las épocas de divagación mental y las respuestas de los niveles de excitación y valencia emocional de los participantes.

5.6. Trabajo Futuro

- La implementación de los modelos de aprendizaje automático para clasificación de mente divagante se realiza mediante el uso de los hiper-parámetros por defecto de la librería scikit-learn. Los hiperparámetros son parámetros que no se aprenden directamente dentro de los estimadores. En scikit-learn, se pasan como argumentos al constructor de las clases del estimador. Los ejemplos típicos incluyen por ejemplo C, kernel y gamma para Support Vector Classifier. Es posible y recomendado buscar en el espacio de hiperparámetros la mejor puntuación de validación cruzada. Para trabajo futuro se considera conveniente la valoración estadística del desempeño de estos algoritmos mediante pruebas basadas en el ajuste combinaciones de los hiper-parámetros, de los estimadores mediante validación cruzada.
- La utilización de librerías para Aprendizaje Automático viene dada por una amplia gama de recursos en la actualidad, para el contexto de este proyecto, partiendo de Scikit-learn como prueba de concepto. Las implementaciones ofrecidas por Keras o Tensorflow para el desarrollo de redes neuronales (profundas) podrían ofrecer otra perspectiva para la realización de experimentos basados en esta técnica.

- Por otro lado, la implementación de algoritmos de clasificación basados en aprendizaje profundo no parece ser efectivas para la clasificación de las señales de EEG en BCI, como lo argumenta (Lotte et al., 2018b) entre otras razones debido a que los datos de entrenamiento disponibles son limitados o la complejidad de los algoritmos en termino computacionales y matemáticos es alta. Aun así, estudios recientes (Hosseini & Guo, 2019) avalan con medidas de desempeño alentadoras para los modelos de clasificación basados en arquitecturas como las Redes Convolucionales profundas. Motivando la investigación futura en el contexto de la computación de alto rendimiento.
- La adopción de protocolos de experimentación y recolección de datos obedecen a una metodología estricta, basada en un amplio fundamento estadístico, experimental, médico y científico. Desde la ingeniería es factible plantear protocolos que permitan realizar captura de datos, pero bien, es necesario, adoptar mecanismos que cuenten con las bases suficientes de la metodología científica de manera similar al planteado para mente divagante en (Rodriguez-Larios & Alaerts, 2021), y así poder contribuir en la creación de nuevos datasets con paradigmas propios que potenciarían la clasificación de los estados de mente-divagante/mindfulness.

ANEXOS

Anexo 1 Repositorio oficial de OSF con el set de datos

<https://osf.io/b6rn9/>

Anexo 2 Notebook en Python con la implementación del proceso detallado.

<https://colab.research.google.com/drive/1u1hggwXZOnnejD2rfLNTBdyxkk1sGg0#scrollTo=3pv7G55QPbY8>

Anexo 3 Certificado Participación con publicación de ponencia en 12 CCC Congreso Colombiano de Computación

https://drive.google.com/file/d/1srk3fu2liNNQOkLj8oFkyfjl-X6_J0Mu/view?usp=sharing

Anexo 4 Certificado Participación 2 Coloquio de Investigación en Ingeniería Facultad de Ingeniería Universidad de Caldas

https://drive.google.com/file/d/1srk3fu2liNNQOkLj8oFkyfjl-X6_J0Mu/view?usp=sharing

Anexo 5 Certificado Proyecto Talento Innovador para Caldas. proyecto de regalías “Fortalecimiento de ciencia, tecnología e innovación en biotecnología para el departamento de Caldas apoyado por Infraestructura computacional avanzada y trabajo colaborativo”

https://drive.google.com/file/d/1srk3fu2liNNQOkLj8oFkyfjl-X6_J0Mu/view?usp=sharing

BIBLIOGRAFÍA / REFERENCIAS

- a, C., Brown, K. W., & Ryan, R. M. (2011). The benefits of being present: Mindfulness and its role in psychological well-being. *Rehabilitation, 84*(c), 2011–2011. <https://doi.org/10.1023/A>
- Abercrombie, H. C., Schaefer, S. M., Larson, C. L., Oakes, T. R., Lindgren, K. A., Holden, J. E., Perlman, S. B., Turski, P. A., Krahn, D. D., Benca, R. M., & Davidson, R. J. (1998). Metabolic rate in the right amygdala predicts negative affect in depressed patients. *Neuroreport, 9*(14), 3301–3307.
- Acı, Ç. İ., Kaya, M., & Mishchenko, Y. (2019). Distinguishing mental attention states of humans via an EEG-based passive BCI using machine learning methods. *Expert Systems with Applications, 134*, 153–166. <https://doi.org/10.1016/j.eswa.2019.05.057>
- Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering, 17*(6). <https://doi.org/10.1109/TKDE.2005.99>
- Aliño, M., Gadea Doménech, M., Pérez San Miguel, J., & Espert Tortajada, R. (2015). Ayahuasca: farmacología, efectos agudos, potencial terapéutico y rituales. In *Revista española de drogodependencias* (Issue 1, pp. 75–91). Asociación Española de Estudio en Drogodependencias, AESED.
- American Academy of Neurology., A., Griffis, J., Visscher, K., Dobbins, A., Gawne, T., DiFrancesco, M., & Szaflarski, J. (2015). Alpha Rhythm and the Default Mode Network: An EEG-fMRI Study. *Neurology, 84*(14 Supplement), P6.021. http://www.neurology.org/content/84/14_Supplement/P6.021
- Anand, A., Li, Y., Wang, Y., Wu, J., Gao, S., Bukhari, L., Mathews, V. P., Kalnin, A., & Lowe, M. J. (2005a). Activity and connectivity of brain mood regulating circuit in depression: A functional magnetic resonance study. *Biological Psychiatry, 57*(10), 1079–1088. <https://doi.org/10.1016/j.biopsych.2005.02.021>
- Anand, A., Li, Y., Wang, Y., Wu, J., Gao, S., Bukhari, L., Mathews, V. P., Kalnin, A., & Lowe, M. J. (2005b). Activity and connectivity of brain mood regulating circuit in depression: a functional magnetic resonance study. *Biological Psychiatry, 57*(10), 1079–1088. <https://doi.org/10.1016/j.biopsych.2005.02.021>
- Anderson, N. D., Lau, M. A., Segal, Z. v., & Bishop, S. R. (2007). Mindfulness-based stress reduction and attentional control. *Clinical Psychology & Psychotherapy, 14*(6), 449–463. <https://doi.org/10.1002/cpp.544>
- Aura Health. (2017). *Aura: Best Mindfulness Meditation App for Stress and Anxiety*. <https://www.aurahealth.io/>
- Austin, J. H. (2006). *Zen-Brain Reflections*. [http://www.elibrary.ibc.ac.th/files/private/Zen-Brain Reflections.pdf](http://www.elibrary.ibc.ac.th/files/private/Zen-Brain%20Reflections.pdf)
- Baer, R. a. (2003). Mindfulness Training as a Clinical Intervention : In *Clinical Psychology: Science and Practice* (Issue 1998, pp. 125–143). <https://doi.org/10.1093/clipsy/bpg015>

- Bao, F. S., Liu, X., & Zhang, C. (2011). PyEEG: an open source Python module for EEG/MEG feature extraction. *Computational Intelligence and Neuroscience*, 2011, 406391. <https://doi.org/10.1155/2011/406391>
- Barachant, A., Bonnet, S., Congedo, M., & Jutten, C. (2012). Multiclass Brain–Computer Interface Classification by Riemannian Geometry. *IEEE Transactions on Biomedical Engineering*, 59(4), 920–928. <https://doi.org/10.1109/TBME.2011.2172210>
- Barachant, A., Bonnet, S., Congedo, M., & Jutten, C. (2013). Classification of covariance matrices using a Riemannian-based kernel for BCI applications. *Neurocomputing*, 112, 172–178. <https://doi.org/10.1016/j.neucom.2012.12.039>
- Barascud Nicolas. (2021). *MEEGkit: EEG and MEG denoising in Python*. <https://nbara.github.io/python-meegkit/modules/meegkit.asr.html>
- Barlow John. (1993). *The Electroencephalogram. Its Patterns and Origins*. The MIT Press. <https://mitpress.mit.edu/books/electroencephalogram>
- Beninger, J., Hamilton-Wright, A., Walker, H. E. K., & Trick, L. M. (2021). Machine learning techniques to identify mind-wandering and predict hazard response time in fully immersive driving simulation. *Soft Computing*, 25(2). <https://doi.org/10.1007/s00500-020-05217-8>
- Berkovich-Ohana, A., Glicksohn, J., & Goldstein, A. (2014). Studying the default mode and its mindfulness-induced changes using EEG functional connectivity. *Social Cognitive and Affective Neuroscience*, 9(10), 1616–1624. <https://doi.org/10.1093/scan/nst153>
- Bhuvaneswari, P., & Kumar, J. S. (2015). Influence of Linear Features in Nonlinear Electroencephalography (EEG) Signals. *Procedia Computer Science*, 47, 229–236. <https://doi.org/10.1016/j.procs.2015.03.202>
- Bishop, S. R., Lau, M., Shapiro, S., Carlson, L., Anderson, N. D., Carmody, J., Segal, Z. v., Abbey, S., Speca, M., Velting, D., & Devins, G. (2004). Mindfulness: A proposed operational definition. *Clinical Psychology: Science and Practice*, 11(3), 230–241. <https://doi.org/10.1093/clipsy/bph077>
- Blum, S., Jacobsen, N. S. J., Bleichner, M. G., & Debener, S. (2019). A Riemannian Modification of Artifact Subspace Reconstruction for EEG Artifact Handling. *Frontiers in Human Neuroscience*, 13. <https://doi.org/10.3389/fnhum.2019.00141>
- Brandmeyer, T., & Delorme, A. (2018). Reduced mind wandering in experienced meditators and associated EEG correlates. *Experimental Brain Research*, 236(9). <https://doi.org/10.1007/s00221-016-4811-5>
- Brefczynski-Lewis, J. a, Lutz, a, Schaefer, H. S., Levinson, D. B., & Davidson, R. J. (2007). Neural correlates of attentional expertise in long-term meditation practitioners. *Proceedings of the National Academy of Sciences of the United States of America*, 104(27), 11483–11488. <https://doi.org/10.1073/pnas.0606552104>
- Brefczynski-Lewis, J. A., Lutz, A., Schaefer, H. S., Levinson, D. B., & Davidson, R. J. (2007a). Neural correlates of attentional expertise in long-term meditation practitioners. *Proceedings of the*

- National Academy of Sciences of the United States of America*, 104(27), 11483–11488.
<https://doi.org/10.1073/pnas.0606552104>
- Brefczynski-Lewis, J. A., Lutz, A., Schaefer, H. S., Levinson, D. B., & Davidson, R. J. (2007b). Neural correlates of attentional expertise in long-term meditation practitioners. *Proceedings of the National Academy of Sciences of the United States of America*, 104(27), 11483–11488.
<https://doi.org/10.1073/pnas.0606552104>
- Brown, K. W., & Ryan, R. M. (n.d.). *The benefits of being present: Mindfulness and its role in psychological well-being*.
- Buckner, R. L., Jessica, A.-H., Daneil, S., Andrews-Hanna, J. R., & Schacter, D. L. (2008). The brain's default network Anatomy, function, and consequence. *Annals of the New York Academy of Sciences*, 1124, 1–38. <https://doi.org/10.1196/annals.1440.011>
- Cabañero, L., Hervás, R., Bravo, J., Rodríguez-Benitez, L., & Nugent, C. (2019). eeglib: computational analysis of cognitive performance during the use of video games. *Journal of Ambient Intelligence and Humanized Computing*. <https://doi.org/10.1007/s12652-019-01592-9>
- Cao, Z. (2020). A review of artificial intelligence for EEG-based brain–computer interfaces and applications. *Brain Science Advances*, 6(3), 162–170.
<https://doi.org/10.26599/BSA.2020.9050017>
- Carmody, J., & Baer, R. a. (2008). Relationships between mindfulness practice and levels of mindfulness, medical and psychological symptoms and well-being in a mindfulness-based stress reduction program. *Journal of Behavioral Medicine*, 31(1), 23–33.
<https://doi.org/10.1007/s10865-007-9130-7>
- Center for Investigating Healthy Minds. (2015). *Center for Investigating Healthy Minds - Center Founder, Dr. Richard J. Davidson*.
<http://www.investigatinghealthyminds.org/cihmDrDavidson.html>
- Center for Open Science. (2021). *OSF Center for Open Science*. <https://osf.io/>. <https://osf.io/>
- Chang, C.-Y., Hsu, S.-H., Pion-Tonachini, L., & Jung, T.-P. (2020). Evaluation of Artifact Subspace Reconstruction for Automatic Artifact Components Removal in Multi-Channel EEG Recordings. *IEEE Transactions on Biomedical Engineering*, 67(4), 1114–1121.
<https://doi.org/10.1109/TBME.2019.2930186>
- Chen, A. C. N., Feng, W., Zhao, H., Yin, Y., & Wang, P. (2008). EEG default mode network in the human brain: Spectral regional field powers. *NeuroImage*, 41(2), 561–574.
<https://doi.org/10.1016/j.neuroimage.2007.12.064>
- Chen, X., Chen, N.-X., Shen, Y.-Q., Li, H.-X., Li, L., Lu, B., Zhu, Z.-C., Fan, Z., & Yan, C.-G. (2020). The subsystem mechanism of default mode network underlying rumination: A reproducible neuroimaging study. *NeuroImage*, 221, 117185.
<https://doi.org/10.1016/j.neuroimage.2020.117185>
- Chen, Y.-T., Lee, H.-H., Shih, C.-Y., Chen, Z.-L., Beh, W.-K., Yeh, S.-L., & Wu, A.-Y. (2020a). *An Effective Entropy-assisted Mind-wandering Detection System with EEG Signals based on MM-SART Database*.

- Chen, Y.-T., Lee, H.-H., Shih, C.-Y., Chen, Z.-L., Beh, W.-K., Yeh, S.-L., & Wu, A.-Y. (2020b). *An Effective Entropy-assisted Mind-wandering Detection System with EEG Signals based on MM-SART Database*.
- Chiesa, A., & Serretti, A. (2009). *Mindfulness-Based Stress Reduction for Stress Management in Healthy People: A Review and Meta-Analysis*. <http://online.liebertpub.com/doi/abs/10.1089/acm.2008.0495>
- Christoff, K., Gordon, A. M., Smallwood, J., Smith, R., & Schooler, J. W. (2009). Experience sampling during fMRI reveals default network and executive system contributions to mind wandering. *Proceedings of the National Academy of Sciences of the United States of America*, *106*(21), 8719–8724. <https://doi.org/10.1073/pnas.0900234106>
- Combrisson, E., & Jerbi, K. (2015). Exceeding chance level by chance: The caveat of theoretical chance levels in brain signal classification and statistical assessment of decoding accuracy. *Journal of Neuroscience Methods*, *250*, 126–136. <https://doi.org/10.1016/j.jneumeth.2015.01.010>
- Craven W. Mark, W. S. J. (n.d.). *Using Neuronal Networks for Data Mining*. 01.
- Dehuri, S., Jagadev, A. K., & Cho, S.-B. (2013). Epileptic Seizure Identification from Electroencephalography Signal Using DE-RBFNs Ensemble. *Procedia Computer Science*, *23*, 84–95. <https://doi.org/10.1016/j.procs.2013.10.012>
- Delorme, A., & Makeig, S. (2004). EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of Neuroscience Methods*, *134*(1), 9–21. <https://doi.org/10.1016/j.jneumeth.2003.10.009>
- Demšar J. (2006). Statistical Comparisons of Classifiers over Multiple Data Sets. *The Journal of Machine Learning Research*, *7*, 1–30.
- Dong, H. W., Mills, C., Knight, R. T., & Kam, J. W. Y. (2021). Detection of mind wandering using EEG: Within and across individuals. *PLOS ONE*, *16*(5). <https://doi.org/10.1371/journal.pone.0251490>
- Ekman, P., Davidson, R. J., Ricard, M., & Alan Wallace, B. (2005). Buddhist and Psychological Perspectives on Emotions and Well-Being. *Current Directions in Psychological Science*, *14*(2), 59–63. <https://doi.org/10.1111/j.0963-7214.2005.00335.x>
- Ekman, P., Davidson, R. J., Ricard, M., Wallace, B. A., & Davidson, J. (2014). Buddhist and Psychological Perspectives Psychological on Emotions and Well-being. *Current Directions in Psychological Science*, *14*(2), 59–63.
- Elahi, Z., Boostani, R., & Motie Nasrabadi, A. (2013). Estimation of hypnosis susceptibility based on electroencephalogram signal features. *Scientia Iranica*, *20*(3), 730–737. <https://doi.org/10.1016/j.scient.2012.07.015>
- Farb, N. a S., Segal, Z. v., Mayberg, H., Bean, J., Mckee, D., Fatima, Z., & Anderson, A. K. (2007). Attending to the present: Mindfulness meditation reveals distinct neural modes of self-reference. *Social Cognitive and Affective Neuroscience*, *2*(4), 313–322. <https://doi.org/10.1093/scan/nsm030>

- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Ferrin Bolaños, C., Loaiza-Correa, H., Pierre-Díaz, J., & Vélez-Ángel, P. (2019). Evaluación del aporte de la covarianza de las señales electroencefalográficas a las interfaces cerebro-computador de imaginación motora para pacientes con lesiones de médula espinal. *Tecnológicas*, 22(46), 213–231. <https://doi.org/10.22430/22565337.1392>
- Fingelkurts, A. A., Fingelkurts, A. A., & Kallio-Tamminen, T. (2015). EEG-guided meditation: A personalized approach. *Journal of Physiology-Paris*, 109(4–6), 180–190. <https://doi.org/10.1016/j.jphysparis.2015.03.001>
- Flook, L., Goldberg, S. B., Pinger, L., Bonus, K., & Davidson, R. J. (2013). Mindfulness for teachers: A pilot study to assess effects on stress, burnout and teaching efficacy. *Mind, Brain and Education : The Official Journal of the International Mind, Brain, and Education Society*, 7(3), 182–195. <https://doi.org/10.1111/mbe.12026>
- Fomina, T., Hohmann, M., Scholkopf, B., & Grosse-Wentrup, M. (2015). Identification of the Default Mode Network with electroencephalography. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 7566–7569. <https://doi.org/10.1109/EMBC.2015.7320143>
- Garrison, K. A., Zeffiro, T. A., Scheinost, D., Constable, R. T., & Brewer, J. A. (2015). Meditation leads to reduced default mode network activity beyond an active task. *Cognitive, Affective & Behavioral Neuroscience*. <https://doi.org/10.3758/s13415-015-0358-3>
- Gasser, T., & Molinari, L. (1996). The analysis of the EEG. *Statistical Methods in Medical Research*, 5(1), 67–99. <https://doi.org/10.1177/096228029600500105>
- Gennady G. Knyazev, Jaroslav Y. Slobodskoj-Plusnin, Andrey V. Bocharov, L. V. P. (2011). The default mode network and EEG alpha oscillations: An independent component analysis. *Brain Research*, 1402, 67–69. <http://www.sciencedirect.com/science/article/pii/S0006899311009863>
- Ghassemi, F., Hassan_Moradi, M., Tehrani-Doost, M., & Abootalebi, V. (2012). Using non-linear features of EEG for ADHD/normal participants' classification. *Procedia - Social and Behavioral Sciences*, 32, 148–152. <https://doi.org/10.1016/j.sbspro.2012.01.024>
- Goldin, P. R., & Gross, J. J. (2010). Effects of mindfulness-based stress reduction (MBSR) on emotion regulation in social anxiety disorder. *Emotion (Washington, D.C.)*, 10(1), 83–91. <https://doi.org/10.1037/a0018441>
- Goleman, D., & Davidson, R. (2017). *Altered Traits: Science Reveals How Meditation Changes Your Mind, Brain, and Body*.
- Gotink, R. A., Meijboom, R., Vernooij, M. W., Smits, M., & Hunink, M. G. M. (2016). 8-week Mindfulness Based Stress Reduction induces brain changes similar to traditional long-term meditation practice – A systematic review. *Brain and Cognition*, 108, 32–41. <https://doi.org/10.1016/j.bandc.2016.07.001>

- Goyal, M., Singh, S., Sibinga, E. M. S., Gould, N. F., Rowland-Seymour, A., Sharma, R., Berger, Z., Sleicher, D., Maron, D. D., Shihab, H. M., Ranasinghe, P. D., Linn, S., Saha, S., Bass, E. B., & Haythornthwaite, J. A. (2014). Meditation programs for psychological stress and well-being: a systematic review and meta-analysis. *JAMA Internal Medicine*, *174*(3), 357–368. <https://doi.org/10.1001/jamainternmed.2013.13018>
- Gramfort, A. (2013). MEG and EEG data analysis with MNE-Python. *Frontiers in Neuroscience*, *7*. <https://doi.org/10.3389/fnins.2013.00267>
- Grandchamp, R., Braboszcz, C., & Delorme, A. (2014). Oculometric variations during mind wandering. *Frontiers in Psychology*, *5*. <https://doi.org/10.3389/fpsyg.2014.00031>
- Granville, V. (2017). *Machine Learning Summarized in One Picture - Data Science Central*. https://www.datasciencecentral.com/profiles/blogs/machine-learning-summarized-in-one-picture?utm_content=buffer0d5bf&utm_medium=social&utm_source=twitter.com&utm_campaign=buffer
- Grégoire Cattan, Pedro Rodrigues, & Marco Congedo. (2018). EEG Alpha Waves dataset [Data set]. *Zenodo*. <https://doi.org/10.5281/zenodo.2348892>
- Groot, J. M., Boayue, N. M., Csifcsák, G., Boekel, W., Huster, R., Forstmann, B. U., & Mittner, M. (2021). Probing the neural signature of mind wandering with simultaneous fMRI-EEG and pupillometry. *NeuroImage*, *224*. <https://doi.org/10.1016/j.neuroimage.2020.117412>
- Hanke, M., Halchenko, Y. O., Sederberg, P. B., Olivetti, E., Fründ, I., Rieger, J. W., Herrmann, C. S., Haxby, J. v, Hanson, S. J., & Pollmann, S. (2009). PyMVPA: a unifying approach to the analysis of neuroscientific data. *Frontiers in Neuroinformatics*, *3*, 3. <https://doi.org/10.3389/neuro.11.003.2009>
- Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., Wieser, E., Taylor, J., Berg, S., Smith, N. J., Kern, R., Picus, M., Hoyer, S., van Kerkwijk, M. H., Brett, M., Haldane, A., del Río, J. F., Wiebe, M., Peterson, P., ... Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, *585*(7825), 357–362. <https://doi.org/10.1038/s41586-020-2649-2>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning*. Springer New York. <https://doi.org/10.1007/978-0-387-84858-7>
- Hjorth, B. (1970). EEG analysis based on time domain properties. *Electroencephalography and Clinical Neurophysiology*, *29*(3), 306–310. [https://doi.org/10.1016/0013-4694\(70\)90143-4](https://doi.org/10.1016/0013-4694(70)90143-4)
- Hosseini, S., & Guo, X. (2019). *Deep Convolutional Neural Network for Automated Detection of Mind Wandering using EEG Signals*. <https://physionet.org/>. (n.d.). <https://physionet.org/>. Retrieved May 10, 2021, from <https://physionet.org/content/?topic=EEG>
- Ichimaru, Y., & Moody, G. B. (1999). Development of the polysomnographic database on CD-ROM. *Psychiatry and Clinical Neurosciences*, *53*(2). <https://doi.org/10.1046/j.1440-1819.1999.00527.x>

- Irrmischer, M., Houtman, S. J., Mansvelder, H. D., Tremmel, M., Ott, U., & Linkenkaer-Hansen, K. (2018). Controlling the Temporal Structure of Brain Oscillations by Focused Attention Meditation. *Human Brain Mapping, 39*(4), 1825–1838. <https://doi.org/10.1002/hbm.23971>
- Jang, J. H., Jung, W. H., Kang, D. H., Byun, M. S., Kwon, S. J., Choi, C. H., & Kwon, J. S. (2011a). Increased default mode network connectivity associated with meditation. *Neuroscience Letters, 487*(3), 358–362. <https://doi.org/10.1016/j.neulet.2010.10.056>
- Jang, J. H., Jung, W. H., Kang, D.-H., Byun, M. S., Kwon, S. J., Choi, C.-H., & Kwon, J. S. (2011b). Increased default mode network connectivity associated with meditation. *Neuroscience Letters, 487*(3), 358–362. <https://doi.org/10.1016/j.neulet.2010.10.056>
- JEN L. TEE, & WAI Y. LEONG. (2018). EEG extraction for meditation. *Journal of Engineering Science and Technology, 13*(7), 2125 – 2135.
- Jia, H. (2011). Neural network in the application of EEG signal classification method. *2011 Seventh International Conference on Computational Intelligence and Security, 1325–1327*. <https://doi.org/10.1109/CIS.2011.294>
- Jin C. (2021). *Detecting Mind-Wandering with Machine Learning: Discovering the Neural Correlates of Mind-Wandering Through Generalizable Machine Learning Classifiers with EEG*. <https://doi.org/10.33612/diss.171835555>
- Jin, C. Y., Borst, J. P., & van Vugt, M. K. (2019). Predicting task-general mind-wandering with EEG. *Cognitive, Affective, & Behavioral Neuroscience, 19*(4). <https://doi.org/10.3758/s13415-019-00707-1>
- Jin, C. Y., Borst, J. P., & Vugt, M. K. (2020). Distinguishing vigilance decrement and low task demands from mind-wandering: A machine learning analysis of EEG. *European Journal of Neuroscience, 52*(9). <https://doi.org/10.1111/ejn.14863>
- Kabat-Zinn, J. (2006). Mindfulness-Based Interventions in Context: Past, Present, and Future. *Clinical Psychology: Science and Practice, 10*(2), 144–156. <https://doi.org/10.1093/clipsy.bpg016>
- kaggle. (2019). *Meditation-EEG-Data*. <https://www.kaggle.com/abyssjumper/meditation-eeedata/code>
- Kaggle. (2021). *Kaggle: Your Machine Learning and Data Science Community*. <https://www.kaggle.com/>
- Kaur, C., & Singh, P. (2015). EEG Derived Neuronal Dynamics during Meditation: Progress and Challenges. *Advances in Preventive Medicine, 2015*. <https://doi.org/10.1155/2015/614723>
- Kawashima, I., & Kumano, H. (2017). Prediction of Mind-Wandering with Electroencephalogram and Non-linear Regression Modeling. *Frontiers in Human Neuroscience, 11*. <https://doi.org/10.3389/fnhum.2017.00365>
- Kim, D.-K., Lee, K.-M., Kim, J., Whang, M.-C., & Kang, S. W. (2013). Dynamic correlations between heart and brain rhythm during Autogenic meditation. *Frontiers in Human Neuroscience, 7*, 414. <https://doi.org/10.3389/fnhum.2013.00414>

- Kim, D.-K., Rhee, J.-H., & Kang, S. W. (2014). Reorganization of the brain and heart rhythm during autogenic meditation. *Frontiers in Integrative Neuroscience*, 7, 109. <https://doi.org/10.3389/fnint.2013.00109>
- Kim, H. (2010). Dissociating the roles of the default-mode, dorsal, and ventral networks in episodic memory retrieval. *NeuroImage*, 50(4), 1648–1657. <https://doi.org/10.1016/j.neuroimage.2010.01.051>
- Kim, H. (2012). A dual-subsystem model of the brain's default network: self-referential processing, memory retrieval processes, and autobiographical memory retrieval. *NeuroImage*, 61(4), 966–977. <https://doi.org/10.1016/j.neuroimage.2012.03.025>
- Kirk, U., & Montague, P. R. (2015). Mindfulness meditation modulates reward prediction errors in a passive conditioning task. *Frontiers in Psychology*, 6, 90. <https://doi.org/10.3389/fpsyg.2015.00090>
- Knyazev, G. G., Slobodskoj-Plusnin, J. Y., Bocharov, A. v., & Pylkova, L. v. (2011). The default mode network and EEG alpha oscillations: An independent component analysis. *Brain Research*, 1402, 67–79. <https://doi.org/10.1016/j.brainres.2011.05.052>
- Koles, Z. J., Lazar, M. S., & Zhou, S. Z. (1990). Spatial patterns underlying population differences in the background EEG. *Brain Topography*, 2(4), 275–284. <https://doi.org/10.1007/BF01129656>
- Koszycki, D., Raab, K., Aldosary, F., & Bradwejn, J. (2010). A multifaceted spiritually based intervention for generalized anxiety disorder: A pilot randomized trial. *Journal of Clinical Psychology*, 66(4), 430–441. <https://doi.org/10.1002/jclp>
- Kothe, C. (2012). *Introduction To Modern Brain-Computer Interface Design - SCCN*. Swartz Center for Computational Neuroscience. https://sccn.ucsd.edu/wiki/Introduction_To_Modern_Brain-Computer_Interface_Design
- Kuhn, M., & Johnson, K. (2013). *Applied Predictive Modeling*. Springer New York. <https://doi.org/10.1007/978-1-4614-6849-3>
- Lahane, P., & Sangaiah, A. K. (2015). An Approach to EEG Based Emotion Recognition and Classification Using Kernel Density Estimation. *Procedia Computer Science*, 48, 574–581. <https://doi.org/10.1016/j.procs.2015.04.138>
- Lawhern, V., Hairston, W. D., McDowell, K., Westerfield, M., & Robbins, K. (2012). Detection and classification of subject-generated artifacts in EEG signals using autoregressive models. *Journal of Neuroscience Methods*, 208(2), 181–189. <https://doi.org/10.1016/j.jneumeth.2012.05.017>
- Lin, H., & Li, Y. (2017). *Using EEG Data Analytics to Measure Meditation*. https://doi.org/10.1007/978-3-319-58466-9_25
- Lomas, T., Ivtzan, I., & Fu, C. H. Y. (2015a). A systematic review of the neurophysiology of mindfulness on EEG oscillations. *Neuroscience & Biobehavioral Reviews*, 57, 401–410. <https://doi.org/10.1016/j.neubiorev.2015.09.018>

- Lomas, T., Ivtzan, I., & Fu, C. H. Y. (2015b). A systematic review of the neurophysiology of mindfulness on EEG oscillations. *Neuroscience & Biobehavioral Reviews*, 57, 401–410. <https://doi.org/10.1016/j.neubiorev.2015.09.018>
- Lomas, T., Ivtzan, I., & Fu, C. H. Y. (2015c). A systematic review of the neurophysiology of mindfulness on EEG oscillations. *Neuroscience & Biobehavioral Reviews*, 57, 401–410. <https://doi.org/10.1016/j.neubiorev.2015.09.018>
- Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A., & Yger, F. (2018a). A review of classification algorithms for EEG-based brain–computer interfaces: a 10 year update. *Journal of Neural Engineering*, 15(3), 031005. <https://doi.org/10.1088/1741-2552/aab2f2>
- Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A., & Yger, F. (2018b). A review of classification algorithms for EEG-based brain–computer interfaces: a 10 year update. *Journal of Neural Engineering*, 15(3), 031005. <https://doi.org/10.1088/1741-2552/aab2f2>
- Lutz, A., Greischar, L. L., Rawlings, N. B., Ricard, M., & Davidson, R. J. (2004). Long-term meditators self-induce high-amplitude gamma synchrony during mental practice. *Proceedings of the National Academy of Sciences of the United States of America*, 101(46), 16369–16373. <https://doi.org/10.1073/pnas.0407401101>
- Lutz, J., Brühl, A. B., Scheerer, H., Jäncke, L., & Herwig, U. (2016a). Neural correlates of mindful self-awareness in mindfulness meditators and meditation-naïve subjects revisited. *Biological Psychology*, 119, 21–30. <https://doi.org/10.1016/j.biopsycho.2016.06.010>
- Lutz, J., Brühl, A. B., Scheerer, H., Jäncke, L., & Herwig, U. (2016b). Neural correlates of mindful self-awareness in mindfulness meditators and meditation-naïve subjects revisited. *Biological Psychology*, 119, 21–30. <https://doi.org/10.1016/j.biopsycho.2016.06.010>
- Maini, V. (2017). *A Beginner's Guide to AI/ML – Machine Learning for Humans*. https://medium.com/machine-learning-for-humans/why-machine-learning-matters-6164faf1df12?source=collection_home---4-----0-----
- Maniar, S., Kalra, R., Shinaman, R., & Longton William. (2017). *WellBrain*. <http://wellbrain.io/>
- Manuello, J., Vercelli, U., Nani, A., Costa, T., & Cauda, F. (2016). Mindfulness meditation and consciousness: An integrative neuroscientific perspective. *Consciousness and Cognition*, 40, 67–78. <https://doi.org/10.1016/j.concog.2015.12.005>
- Mathworks. (2017). *Machine Learning with MATLAB*. https://la.mathworks.com/campaigns/offers/machine-learning-with-matlab.html?s_tid=hp_offer_ml_ebok
- Mayberg, H. S., Lozano, A. M., Voon, V., McNeely, H. E., Seminowicz, D., Hamani, C., Schwalb, J. M., & Kennedy, S. H. (2005). Deep brain stimulation for treatment-resistant depression. *Neuron*, 45(5), 651–660. <https://doi.org/10.1016/j.neuron.2005.02.014>

- McBride, J. C., Zhao, X., Munro, N. B., Jicha, G. A., Schmitt, F. A., Kryscio, R. J., Smith, C. D., & Jiang, Y. (2015). Sugihara causality analysis of scalp EEG for detection of early Alzheimer's disease. *NeuroImage: Clinical*, *7*, 258–265. <https://doi.org/10.1016/j.nicl.2014.12.005>
- McKenna, D. J. (2004). Clinical investigations of the therapeutic potential of ayahuasca: rationale and regulatory challenges. *Pharmacology & Therapeutics*, *102*(2), 111–129. <https://doi.org/10.1016/j.pharmthera.2004.03.002>
- McKinney, W. (2010). *Data Structures for Statistical Computing in Python*. 56–61. <https://doi.org/10.25080/Majora-92bf1922-00a>
- Mitchell, T. M. (1997). *Machine Learning* (McGraw-Hill International Editions McGraw-Hill international editions - computer science series McGraw-Hill series in artificial intelligence McGraw-Hill series in computer science McGraw-Hill series in computer science: Artificial intelligence, Ed.).
- Mohammadi, M., Al-Azab, F., Raahemi, B., Richards, G., Jaworska, N., Smith, D., de la Salle, S., Blier, P., & Knott, V. (2015). Data mining EEG signals in depression for their diagnostic value. *BMC Medical Informatics and Decision Making*, *15*, 108. <https://doi.org/10.1186/s12911-015-0227-6>
- Moody, G. B., Mark, R. G., & Goldberger, A. L. (2001). PhysioNet: a Web-based resource for the study of physiologic signals. *IEEE Engineering in Medicine and Biology Magazine*, *20*(3). <https://doi.org/10.1109/51.932728>
- Mullen, T. R., Kothe, C. A. E., Chi, Y. M., Ojeda, A., Kerth, T., Makeig, S., Jung, T.-P., & Cauwenberghs, G. (2015). Real-time neuroimaging and cognitive monitoring using wearable dry EEG. *IEEE Transactions on Biomedical Engineering*, *62*(11), 2553–2567. <https://doi.org/10.1109/TBME.2015.2481482>
- Neuner, I., Arrubla, J., Werner, C. J., Hitz, K., Boers, F., Kawohl, W., & Shah, N. J. (2014). The default mode network and EEG regional spectral power: a simultaneous fMRI-EEG study. *PLoS One*, *9*(2), e88214. <https://doi.org/10.1371/journal.pone.0088214>
- Neuralink. (n.d.). *Home - Neuralink*. Retrieved May 23, 2021, from <https://neuralink.com/>
- Oken, B., Ahani, A., Wahbeh, H., Nezamfar, H., Miller, M., Erdogmus, D., & Goodrich, E. (2014). Signal Processing and Machine Learning of EEG and Respiration Changes During Mindfulness Meditation State. *The Journal of Alternative and Complementary Medicine*, *20*(5), A25–A25. <https://doi.org/10.1089/acm.2014.5061.abstract>
- Orhan, U., Hekim, M., & Ozer, M. (2011). EEG signals classification using the K-means clustering and a multilayer perceptron neural network model. *Expert Systems With Applications*, *38*, 13475–13481. <https://doi.org/10.1016/j.eswa.2011.04.149>
- Othman, M., Wahab, A., Karim, I., Dzulkipli, M. A., & Alshaikli, I. F. T. (2013). EEG Emotion Recognition Based on the Dimensional Models of Emotions. *Procedia - Social and Behavioral Sciences*, *97*, 30–37. <https://doi.org/10.1016/j.sbspro.2013.10.201>

- Parvinnia, E., Sabeti, M., Zolghadri Jahromi, M., & Boostani, R. (2014). Classification of EEG Signals using adaptive weighted distance nearest neighbor algorithm. *Journal of King Saud University - Computer and Information Sciences*, 26(1), 1–6. <https://doi.org/10.1016/j.jksuci.2013.01.001>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., & Prettenhofer, P. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- PhysioNet. (n.d.). *AHA Database Sample Excluded Record*. Retrieved May 17, 2021, from <https://physionet.org/content/ahadb/1.0.0/>
- Pizzagalli, D. A. (2011). Frontocingulate dysfunction in depression: toward biomarkers of treatment response. *Neuropsychopharmacology: Official Publication of the American College of Neuropsychopharmacology*, 36(1), 183–206. <https://doi.org/10.1038/npp.2010.166>
- Prerau, M. J., Brown, R. E., Bianchi, M. T., Ellenbogen, J. M., & Purdon, P. L. (2017). Sleep Neurophysiological Dynamics Through the Lens of Multitaper Spectral Analysis. *Physiology*, 32(1), 60–92. <https://doi.org/10.1152/physiol.00062.2015>
- Raichle, M. E. (2015). The Brain's Default Mode Network. *Annual Review of Neuroscience*. <https://doi.org/10.1146/annurev-neuro-071013-014030>
- Rechy-Ramirez, E. J., & Hu, H. (2015). Bio-signal based control in assistive robots: a survey. *Digital Communications and Networks*, 1(2), 85–101. <https://doi.org/10.1016/j.dcan.2015.02.004>
- Rivet, B., Souloumiac, A., Attina, V., & Gibert, G. (2009). xDAWN Algorithm to Enhance Evoked Potentials: Application to Brain–Computer Interface. *IEEE Transactions on Biomedical Engineering*, 56(8), 2035–2043. <https://doi.org/10.1109/TBME.2009.2012869>
- Rodriguez-Larios, J., & Alaerts, K. (2021). EEG alpha–theta dynamics during mind wandering in the context of breath focus meditation: An experience sampling approach with novice meditation practitioners. *European Journal of Neuroscience*, 53(6). <https://doi.org/10.1111/ejn.15073>
- Saha, S., Mamun, K. A., Ahmed, K., Mostafa, R., Naik, G. R., Darvishi, S., Khandoker, A. H., & Baumert, M. (2021). Progress in Brain Computer Interface: Challenges and Opportunities. *Frontiers in Systems Neuroscience*, 15. <https://doi.org/10.3389/fnsys.2021.578875>
- Scheeringa, R., Bastiaansen, M. C. M., Petersson, K. M., Oostenveld, R., Norris, D. G., & Hagoort, P. (2008). Frontal theta EEG activity correlates negatively with the default mode network in resting state. *International Journal of Psychophysiology*, 67(3), 242–251. <https://doi.org/10.1016/j.ijpsycho.2007.05.017>
- Shams, W. K., Wahab, A., & Fakhri, I. (2013). Affective Computing Model Using Source-temporal Domain. *Procedia - Social and Behavioral Sciences*, 97, 54–62. <https://doi.org/10.1016/j.sbspro.2013.10.204>
- Shneiderman, B., & Plaisant, C. (2009). *Designing the User Interface: Strategies for Effective Human-Computer Interaction*. Nature Publishing Group.
- Shoemaker, A. (2014). *Ayahuasca Medicine: The Shamanic World of Amazonian Sacred Plant Healing*. <https://doi.org/9781620551936>

- Silicon Valley Bank. (2018). *China Startup Outlook 2018 Key insights from the Silicon Valley Bank Startup Outlook Survey*.
https://www.svb.com/uploadedFiles/Content/Trends_and_Insights/Reports/Startup_Outlook_Report/China/SVB-SUO-China-report.pdf?utm_content=buffer1cf63&utm_medium=social&utm_source=twitter.com&utm_campaign=buffer
- Simon, R. (2015). *The default mode network as a biomarker for monitoring the therapeutic effects of meditation*. 6(June), 1–10. <https://doi.org/10.3389/fpsyg.2015.00776>
- Smallwood, J., Fitzgerald, A., Miles, L. K., & Phillips, L. H. (2009). Shifting moods, wandering minds: negative moods lead the mind to wander. *Emotion (Washington, D.C.)*, 9(2), 271–276. <https://doi.org/10.1037/a0014855>
- Sörnmo, L., & Laguna, P. (2005). Bioelectrical Signal Processing in Cardiac and Neurological Applications. In *Bioelectrical Signal Processing in Cardiac and Neurological Applications*. Elsevier Inc. <https://doi.org/10.1016/B978-0-12-437552-9.X5000-4>
- Stanford Center for Reproducible Neuroscience. (2021, December). <https://openneuro.org/search/modality/eeg>.
- Subasi, A., & Erçelebi, E. (2005). Classification of EEG signals using neural network and logistic regression. *Computer Methods and Programs in Biomedicine*, 78(2), 87–99. <https://doi.org/10.1016/j.cmpb.2004.10.009>
- TADDEI, A., DISTANTE, G., EMDIN, M., PISANI, P., MOODY, G. B., ZEELENBERG, C., & MARCHESI, C. (1992). The European ST-T database: standard for evaluating systems for the analysis of ST-T changes in ambulatory electrocardiography. *European Heart Journal*, 13(9). <https://doi.org/10.1093/oxfordjournals.eurheartj.a060332>
- Tang, Y.-Y., Hölzel, B. K., & Posner, M. I. (2015). The neuroscience of mindfulness meditation. *Nature Reviews Neuroscience*, 16(4), 213–225. <https://doi.org/10.1038/nrn3916>
- Tasika, N. J., Haque, M. H., Rimo, M. B., al Haque, M., Alam, S., Tamanna, T., Rahman, M. A., & Parvez, M. Z. (2020). A Framework for Mind Wandering Detection using EEG Signals. *2020 IEEE Region 10 Symposium (TENSYP)*. <https://doi.org/10.1109/TENSYP50017.2020.9230790>
- Taylor, V. A., Daneault, V., Grant, J., Scavone, G., Breton, E., Roffe-vidal, S., Courtemanche, J., Lavarenne, A. S., Marrelec, G., Benali, H., & Beauregard, M. (2013). Impact of meditation training on the default mode network during a restful state. *Social Cognitive and Affective Neuroscience*, 8(1). <https://doi.org/10.1093/scan/nsr087>
- Taylor, V. A., Daneault, V., Grant, J., Scavone, G., Breton, E., Roffe-Vidal, S., Courtemanche, J., Lavarenne, A. S., Marrelec, G., Benali, H., & Beauregard, M. (2013). Impact of meditation training on the default mode network during a restful state. *Social Cognitive and Affective Neuroscience*, 8(1), 4–14. <https://doi.org/10.1093/scan/nsr087>
- The SciPy community. (2021). *SciPy*. <https://docs.scipy.org/doc/scipy/reference/generated/scipy.signal.butter.html>

- van Loon, R. (2018). *Machine Learning Explained: Understanding Supervised, Unsupervised, and Reinforcement Learning*. Data Science Central. <https://www.datasciencecentral.com/profiles/blogs/machine-learning-explained-understanding-supervised-unsupervised>
- Vieira, S., Garcia-Dias, R., & Lopez Pinaya, W. H. (2020). A step-by-step tutorial on how to build a machine learning model. In *Machine Learning* (pp. 343–370). Elsevier. <https://doi.org/10.1016/B978-0-12-815739-8.00019-5>
- Vieira, S., Lopez Pinaya, W. H., & Mechelli, A. (2019). Introduction to machine learning. In *Machine Learning: Methods and Applications to Brain Disorders* (pp. 1–20). Elsevier. <https://doi.org/10.1016/B978-0-12-815739-8.00001-8>
- Wahlbeck, K., Anderson, P., Basu, S., McDaid, D., & Stuckler, D. (2011). Impact of economic crises on mental health. *World Health*, 34. <http://www.euro.who.int/en/home>
- WHO. (2009). Global Health Risks: Mortality and burden of disease attributable to selected major risks. *Bulletin of the World Health Organization*, 87, 646–646. <https://doi.org/10.2471/BLT.09.070565>
- Witten, I. H., Frank, E., & Hall, M. A. (2011). Data Mining Practical Machine Learning Tools and Techniques. In *Zhurnal Eksperimental'noi i Teoreticheskoi Fiziki* (Third Edit). <http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:No+Title#0>
- Wood, I. K. (1996). Neuroscience: Exploring the brain. *Journal of Child and Family Studies*, 5(3), 377–379. <https://doi.org/10.1007/bf02234670>
- World Federation For Mental Health (WFMH). (2012). Depression: A Global Crisis. *World Mental Health Day*, 32. http://www.who.int/mental_health/management/depression/wfmh_paper_depression_wmhd_2012.pdf.
- World Health Organization. (2001). *MENTAL HEALTH A Call for Action by World Health Ministers*. http://www.who.int/mental_health/advocacy/en/Call_for_Action_MoH_Intro.pdf
- World Health Organization. (2012). Depression, A Hidden Burden. In *Fact sheet N°369*. <http://www.who.int/mediacentre/factsheets/fs369/en/>
- World Health Organization. (2015). *Fact sheet N°369 WHO Depression*. World Health Organization. http://www.who.int/mental_health/management/depression/en/
- Yao, M. (2018). *6 Ways AI Transforms How We Develop Software*. <https://www.topbots.com/6-ways-ai-transforms-develop-software/>
- Yu, X., Chum, P., & Sim, K.-B. (2014). Analysis the effect of PCA for feature reduction in non-stationary EEG based motor imagery of BCI system. *Optik*, 125(3), 1498–1502. <https://doi.org/10.1016/j.ijleo.2013.09.013>
- Zainuddin, Z., Huong, L. K., & Pauline, O. (2012). On the Use of Wavelet Neural Networks in the Task of Epileptic Seizure Detection from Electroencephalography Signals. *Procedia Computer Science*, 11, 149–159. <https://doi.org/10.1016/j.procs.2012.09.016>

