



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

PROCESAMIENTO DIGITAL DE SEÑALES DE EEG PARA CLASIFICACIÓN DE
TRASTORNOS PSICÓTICOS MEDIANTE APRENDIZAJE DE MÁQUINAS

MEMORIA PARA OPTAR AL TÍTULO DE
INGENIERO CIVIL ELÉCTRICO

MAURICIO JAVIER LUNA DE LUIS

PROFESOR GUÍA:
ÁNGEL JIMÉNEZ MOLINA

MIEMBROS DE LA COMISIÓN:
FRANCISCO RIVERA SERRANO
PABLO GASPAR RAMOS

SANTIAGO DE CHILE
2021

RESUMEN DE LA MEMORIA PARA OPTAR
AL TÍTULO DE INGENIERO CIVIL ELÉCTRICO
POR: MAURICIO JAVIER LUNA DE LUIS
FECHA: 22/03/2021
PROF. GUÍA: ÁNGEL JIMÉNEZ MOLINA

PROCESAMIENTO DIGITAL DE SEÑALES DE EEG PARA CLASIFICACIÓN DE TRASTORNOS PSICÓTICOS MEDIANTE APRENDIZAJE DE MÁQUINAS

El siguiente trabajo muestra la implementación de metodologías de procesamiento de señales de electroencefalograma y extracción de características de series de tiempo para resolver el problema de clasificación de psicosis utilizando señales obtenidas por la Clínica Psiquiátrica de la Universidad de Chile. Las señales corresponden a mediciones de electroencefalograma (EEG) de grupos de pacientes con distintos grados de psicosis, además de pacientes sanos, que realizaron un conjunto de tareas psicológicas.

Los métodos utilizados en esta memoria consisten en procesamiento de señales utilizando librerías especializadas del software de programación Matlab siguiendo cinco metodologías distintas, seguido de su posterior clasificación utilizando librerías de extracción de características de series de tiempo y librerías de clasificación de datos para el software de programación Python. Se estudiarán dos metodologías de extracción de características y diversas metodologías de clasificación de psicosis.

Las metodologías de procesamiento de señales consisten en la utilización de filtros de frecuencia pasabanda por medio de 2 tipos de filtros, reducción en la frecuencia de muestreo de las señales y eliminación de ruido o componentes innecesarias en las señales. Las 5 metodologías de procesamiento consisten básicamente en la permutación de los procesos anteriores. Luego, las muestras de estas bases de datos serán procesadas por algoritmos de extracción de características de dos librerías distintas, las cuáles finalmente se utilizarán para entrenar 6 tipos de algoritmos de Machine/Deep Learning que utilizan técnicas de aprendizaje supervisado para clasificar estas muestras.

Los resultados obtenidos por los clasificadores corresponden a porcentajes de precisión al clasificar las distintas muestras de las bases de datos, por ejemplo, clasificar grupo de control y pacientes con esquizofrenia. Por lo tanto, el objetivo será encontrar la base de datos y metodología de extracción de características que obtenga la mejor precisión posible para un conjunto de muestras determinado, según las etiquetas de clase que estas muestras tengan.

Tabla de Contenido

Índice de Tablas	iv
Índice de Ilustraciones	vi
Introducción	1
1. Marco teórico	3
1.1. Electroencefalograma	3
1.2. Base de datos	3
1.3. Procesamiento digital de señales	5
1.4. Extracción de características de las señales	6
1.4.1. Intensidad de potencia espectral y Razón de intensidad relativa	7
1.4.2. Dimensión fractal	8
1.4.3. Parámetros de Hjorth	9
1.4.4. Entropía espectral	9
1.4.5. Entropía de permutación	9
1.4.6. Entropía SVD	9
1.4.7. Información de Fisher	10
1.4.8. Análisis de fluctuación sin tendencia	10
1.5. Selección de canales de las señales	10
1.6. Clasificación de psicosis y selección de características	12
2. Metodología	15
2.1. Ajustes de bases de datos	15
2.2. Procesamiento digital de señales	17
2.2.1. Filtrado pasabanda	17
2.2.2. Reducción de frecuencia de muestreo	17
2.2.3. Eliminación de artefactos	18
2.3. Extracción de características	18
2.4. Clasificación de psicosis y análisis de características	19
3. Revisión Bibliográfica	20
4. Desarrollo	28
4.1. Procesamiento de señales	28
4.2. Extracción de características	29

4.3.	Clasificación de datos usando tarea Resting State	29
4.3.1.	Etiquetado y separación de conjuntos	29
4.3.2.	Clasificadores y ajuste de hiperparámetros	30
4.3.3.	Resultados preliminares de clasificación binaria	32
4.3.4.	Selección de canales	41
4.3.5.	Clasificación de EQZ con selección de características	45
4.3.6.	Clasificación de otros conjuntos con selección	47
4.4.	Clasificación de datos usando tarea Double Flash	53
4.4.1.	Clasificación de esquizofrenia sin selección	53
4.4.2.	Clasificación de EQZ con selección de características	55
4.4.3.	Clasificación binaria de psicosis	57
4.4.4.	Clasificación de psicosis con selección de características	58
4.5.	Clasificación de datos usando tarea Sternberg	59
4.5.1.	Clasificación de FEP sin selección	59
4.5.2.	Clasificación de FEP con selección de características	60
4.5.3.	Clasificación de APS sin selección	61
4.5.4.	Clasificación de APS con selección de características	62
4.5.5.	Clasificación de psicosis sin selección	63
4.5.6.	Clasificación de psicosis con selección de características	64
4.6.	Clasificación de datos usando tarea Moving Dots	65
4.6.1.	Clasificación de psicosis sin selección	65
4.6.2.	Clasificación de psicosis con selección de características	66
4.7.	Clasificación de datos usando tarea MMN Emocional	67
4.7.1.	Clasificación de APS sin selección	67
4.7.2.	Clasificación de APS con selección de características	68
4.8.	Análisis clínico y técnico de características	69
4.8.1.	Conjuntos Resting State y Double Flash	69
4.8.2.	Conjuntos Sternberg, MVD y MMN Emocional	72
	Conclusión	76
	Bibliografía	79

Índice de Tablas

1.1. Distribución de grupos por tarea y cantidad total de sujetos.	5
4.1. Validación cruzada de Monte Carlo, metodología 1 con 1224 características. .	32
4.2. Validación cruzada de Monte Carlo, metodología 2 con 1224 características. .	33
4.3. Validación cruzada de Monte Carlo, metodología 3 con 1224 características. .	34
4.4. Validación cruzada de Monte Carlo, metodología 4 con 1224 características. .	35
4.5. Validación cruzada de Monte Carlo, metodología 5 con 1224 características. .	36
4.6. Validación cruzada, conjunto 128 Hz con 1440 características.	37
4.7. Validación cruzada, conjunto 256 Hz con 1440 características.	38
4.8. Validación cruzada, conjunto 128 Hz con 2880 características	39
4.9. Validación cruzada, conjunto 256 Hz con 2880 características	40
4.10. Precisión validación cruzada, conjuntos 128 y 256 Hz con selección de canales.	41
4.11. Sensibilidad validación cruzada, conjuntos 128 y 256 Hz con selección de canales.	42
4.12. Especificidad validación cruzada, conjuntos 128 y 256 Hz con selección de canales	43
4.13. Validación cruzada, EQZ vs Control 256 Hz, con selección de 23 características.	45
4.14. Validación cruzada, Esquizofrenia vs Control 128 Hz, con 28 características. .	46
4.15. Validación cruzada, APS vs CNTA 128 Hz, con selección de 4 características.	47
4.16. Validación cruzada, APS vs CNTA 256 Hz, con selección de 5 características.	48
4.17. Validación cruzada, Psicosis vs Control 128 Hz, con 23 características.	49
4.18. Validación cruzada, Psicosis vs Control 256 Hz, con 19 características.	50
4.19. Validación cruzada, problema de 3 clases, ambos conjuntos.	51
4.20. Validación cruzada, problema de 5 clases, ambos conjuntos.	52
4.21. Validación cruzada, tarea DBF, filtro filtfilt.	53
4.22. Validación cruzada, tarea DBF, metodología eegfilt.	54
4.23. Validación cruzada, DBF filtfilt con 18 características.	55
4.24. Validación cruzada, DBF eegfilt con 17 características.	56
4.25. Validación cruzada, Psicosis vs Control, tarea DBF.	57
4.26. Validación cruzada, Psicosis vs Control, DBF 26 características.	58
4.27. Validación cruzada, FEP vs CNTF, Sternberg.	59
4.28. Validación cruzada, FEP vs CNTF, Sternberg con 12 características.	60
4.29. Validación cruzada, APS vs CNTA, tarea Sternberg.	61
4.30. Validación cruzada, APS vs CNTA, tarea Sternberg con 11 características. .	62
4.31. Validación cruzada, Psicosis vs Control, tarea Sternberg.	63
4.32. Validación cruzada, Psicosis vs Control, tarea Sternberg con 11 características.	64
4.33. Validación cruzada, Psicosis vs Control, tarea Moving Dots.	65
4.34. Validación cruzada, Psicosis vs Control, tarea Moving Dots con 13 características.	66

4.35. Validación cruzada, APS vs Control, tarea MMN Emocional.	67
4.36. Validación cruzada, APS vs Control, MMN Emocional con 12 características.	68

Índice de Ilustraciones

1.1. Resting State.	4
1.2. Double Flash.	4
1.3. Sternberg.	4
1.4. MMN Emocional.	4
1.5. Moving Dots.	4
1.6. Ejemplo de matriz de confusión para 3 clases	13
2.1. Distribución general de electrodos en cuero cabelludo.	16
2.2. Ejemplo de señal de EEG	16
3.1. Resultados de clasificación.	21
3.2. Resultados de clasificación para las distintas muestras.	22
3.3. Resultados de clasificación para distintos conjuntos de características.	23
3.4. Resultados de clasificación para distintos conjuntos.	27
4.1. Matrices de confusión metodología 1, 1224 características.	32
4.2. Matrices de confusión metodología 2, 1224 características.	33
4.3. Matrices de confusión metodología 3, 1224 características.	34
4.4. Matrices de confusión metodología 4, 1224 características.	35
4.5. Matrices de confusión metodología 5, 1224 características.	36
4.6. Matrices de confusión conjunto 128 Hz, 1440 características.	37
4.7. Matrices de confusión conjunto 256 Hz, 1440 características.	38
4.8. Matrices de confusión conjunto 128 Hz, 2880 características.	39
4.9. Matrices de confusión conjunto 256 Hz, 2880 características.	40
4.10. Gráficos de precisión conjunto 256 Hz, 23 características.	45
4.11. Gráficos de precisión conjunto 128 Hz, 28 características.	46
4.12. Gráficos de precisión APS vs CNTA, 128 Hz, 4 características.	47
4.13. Gráficos de precisión APS vs CNTA, 256 Hz, 5 características.	48
4.14. Gráficos de precisión Psicosis vs. Control, 128 Hz, 23 características.	49
4.15. Gráficos de precisión Psicosis vs Control, 256 Hz, 19 características.	50
4.16. Gráficos para problema de 3 clases.	51
4.17. Gráficos para problema de 5 clases.	52
4.18. Gráficos de precisión EQZ vs Control, tarea DBF filtro filtfilt.	53
4.19. Gráficos de precisión EQZ vs Control, tarea DBF filtro eegfilt.	54
4.20. Gráficos EQZ vs Control, tarea DBF eegfilt con 18 características.	55
4.21. Gráficos EQZ vs Control, tarea DBF eegfilt con 17 características.	56
4.22. Gráficos de precisión, Psicosis vs Control, tarea DBF.	57

4.23. Gráficos de precisión, Psicosis vs Control, tarea DBF con 26 características. .	58
4.24. Gráficos de precisión, FEP vs CNTF, tarea Sternberg.	59
4.25. Gráficos de precisión, FEP vs CNTF, tarea Sternberg con 12 características.	60
4.26. Gráficos de precisión, APS vs CNTA, tarea Sternberg.	61
4.27. Gráficos de precisión, APS vs CNTA, tarea Sternberg con 11 características.	62
4.28. Gráficos de precisión, Psicosis vs Control, tarea Sternberg.	63
4.29. Gráficos de precisión, Psicosis vs Control, tarea Sternberg con 11 características.	64
4.30. Gráficos de precisión, Psicosis vs Control, tarea Moving Dots.	65
4.31. Gráficos de precisión, Psicosis vs Control, tarea Moving Dots con 13 caracte- rísticas.	66
4.32. Gráficos de precisión, APS vs Control, tarea MMN Emocional.	67
4.33. Gráficos de precisión, APS vs Control, tarea MMN Emocional con 12 caracte- rísticas.	68
4.34. Asociación de características a distribución de electrodos, RS y DBF.	69
4.35. Lóbulos del cerebro	70
4.36. Histogramas de características, ambos conjuntos.	71
4.37. Histogramas de características para STB, MVD, MMN y total.	73
4.38. Asociación de características a distribución de electrodos, STB, MVD y MMN.	74

Introducción

La psicosis es una palabra usada para describir condiciones que afectan la mente en la que ha existido una pérdida de contacto con la realidad, es decir, dificultades para distinguir qué es real y qué no lo es. Síntomas de la psicosis pueden incluir delirios, alucinaciones, como por ejemplo ver o escuchar cosas que otros no pueden percibir, o trastornos del pensamiento. Otros síntomas de mayor gravedad son la pérdida o ausencia de rasgos o habilidades normales, como habla incoherente o sin sentido, comportamientos que sean inapropiados para una situación. Una persona en un episodio psicótico puede experimentar depresión, ansiedad, problemas de sueño, aislamiento social, falta de motivación y dificultad para funcionar en general[1].

Para diagnosticar un trastorno psicótico, los médicos deben elaborar un historial médico y psiquiátrico incluyendo la posibilidad de efectuar exámenes físicos tales como análisis de sangre e incluso imágenes del cerebro, como las imágenes por resonancia magnética, para descartar enfermedades físicas o el uso de drogas como la cocaína o el LSD. Los médicos o profesionales de la salud mental utilizarán herramientas de evaluación y entrevista especialmente diseñadas para decidir si la persona tiene un trastorno psicótico[2] como, por ejemplo, el Manual Diagnóstico y Estadístico de Trastornos Mentales o DSM-V por sus siglas en inglés. Sin embargo, estas herramientas tradicionales de diagnóstico pueden ser inexactas puesto que pacientes con trastornos psicóticos tienden a ocultar intencionalmente sus síntomas, e incluso expertos suelen tener dificultades de diferenciar trastornos psicóticos, como la esquizofrenia, de otras enfermedades mentales, como la paranoia, debido a similitudes en los síntomas[3].

Por lo que surge la necesidad de crear modelos de clasificación de trastornos psicóticos en base a biomarcadores o marcadores clínicos (indicadores medibles de un estado o condición biológica) objetivos y cuantitativos que permitan mejorar la precisión en el diagnóstico de trastornos psicóticos. En este contexto, las técnicas utilizadas para la obtención de marcadores clínicos se basan en el estudio de la dinámica temporal de las funciones cerebrales, dentro de las cuáles se encuentra la electroencefalografía o EEG. El electroencefalograma es una técnica de bajo costo que se usa para controlar el estado del cerebro mediante el uso de electrodos posicionados a lo largo del cuero cabelludo, y permite medir fluctuaciones de voltaje proveniente de las actividades entre las neuronas del cerebro.

Al tener datos sin procesar de exámenes de EEG, mediante procesamiento de señales se pueden filtrar datos no deseados, extraer características de las señales o visualizar potenciales evocados (Event-related Potentials o ERP) que permitan identificar y entender que elementos de las señales EEG se pueden asociar trastornos psicóticos o cuáles no. Esto último implica la utilización de herramientas de análisis de datos conocidas como técnicas de aprendizaje

de máquinas también conocidas en inglés como Machine Learning o Deep Learning. Estas técnicas permiten darles significado a las características extraídas por el procesamiento de señales EEG y por lo demás posibilitan la construcción de clasificadores y herramientas predictivas de trastornos psicóticos.

Por lo tanto, el objetivo de esta memoria consiste en realizar procesamiento de señales e ingeniería de características a las señales cerebrales de pacientes, extraídas mediante EEG, con el fin de realizar un análisis comparativo de características de las señales EEG para así determinar cuáles de estas son las más relevantes para la clasificación de trastornos psicóticos, mediante la utilización de herramientas de aprendizaje de máquinas y análisis de series de tiempo o señales discretas. Para ello, se utilizará la base de datos obtenida por el PsiquisLab de la Clínica Psiquiátrica de la Universidad de Chile, que consiste en señales de electroencefalograma de pacientes con distintos grados de psicosis y grupos de control que fueron sometidos a una serie de tareas audiovisuales, las cuáles serán procesadas usando herramientas de programación. En las secciones siguientes de este informe se definirán conceptos importantes en la sección de marco teórico, las metodologías a utilizar para resolver el problema, seguido de una revisión bibliográfica para estudiar procedimientos similares en la literatura, luego pasar por el desarrollo del problema y obtención de resultados, para finalmente concluir y obtener análisis tanto técnicos como clínicos sobre el trabajo en general.

Capítulo 1

Marco teórico

1.1. Electroencefalograma

Un electroencefalograma es una prueba que detecta la actividad eléctrica del cerebro mediante pequeños discos metálicos (electrodos) fijados sobre el cuero cabelludo. Las neuronas cerebrales se comunican a través de impulsos eléctricos y están activas todo el tiempo, incluso mientras duermes. Esta actividad se manifiesta como líneas onduladas en un registro de electroencefalograma. Un EEG es capaz de determinar cambios en la actividad cerebral que pueden ser útiles para diagnosticar trastornos cerebrales, especialmente epilepsia u otros trastornos convulsivos.¹

1.2. Base de datos

La base de datos a utilizar consiste en señales de electroencefalograma muestreadas a una frecuencia de 2048 Hz, y en formato de datos Biosemi (BDF, por sus siglas en inglés) correspondientes a 5 grupos de pacientes, los que encuentran etiquetados de la siguiente forma:

- **APS:** Atenuated Psychosis Syndrome, 30 pacientes con pródromo de esquizofrenia.
- **FEP:** First Episode Psychosis, 18 pacientes con menos de 2 años desde su primer episodio psicótico de esquizofrenia.
- **EQZ:** Esquizofrenia crónica con más de 2 años desde su primer episodio psicótico de esquizofrenia. 10 pacientes.
- **CNTA:** Grupo de control compuesto por 10 adolescentes (14-18 años)
- **CNTF:** Grupo de control compuesto por 49 adultos (19-30 años)

Además, estos grupos fueron sometidos a 5 tareas distintas para medir sus señales cerebrales al realizar ciertas acciones:

- **Resting State:** Sujetos mantienen ojos abiertos por 2 minutos y ojos cerrados por 2 minutos.

¹Electroencefalograma, Clínica Mayo <https://www.mayoclinic.org/es-es/tests-procedures/eeg/about/pac-20393875>

- **Double Flash:** Prueba audiovisual donde se presenta un punto blanco parpadeante y un sonido monótono de corta duración. Sujetos deben indicar cuantos flash observaron (0, 1 o 2), el sonido es un distractor que produce una ilusión visual.
- **Sternberg:** Se presentan una serie de letras en una pantalla de forma sucesiva, luego de una pausa aparece otra letra y sujetos presionan un botón si es que esta última letra se encontraba en la serie.
- **MMN Emocional:** estímulo auditivo/musical. Se presentan una serie de sonidos estándar asociados a una emoción (i.e violín triste) seguido de un sonido desviante (i.e violín alegre). Se realizaron 5 combinaciones distintas de sonido.
- **Moving Dots:** A sujetos se les presenta una pantalla en negro con puntos blancos que se mueven con cierta sincronización en el espacio.

Para entender de mejor forma cuales son las funciones cerebrales que se intenta obtener en cada tarea, se incluyen las siguientes imágenes:



Figura 1.1: Resting State.

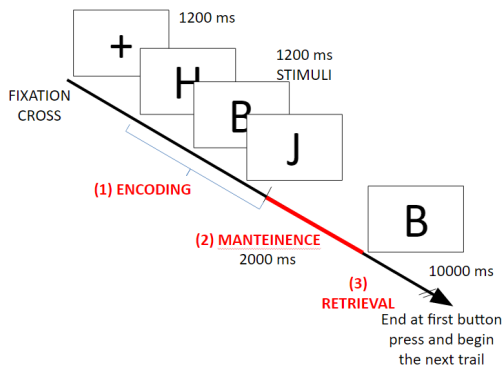


Figura 1.3: Sternberg.




Figura 1.2: Double Flash.

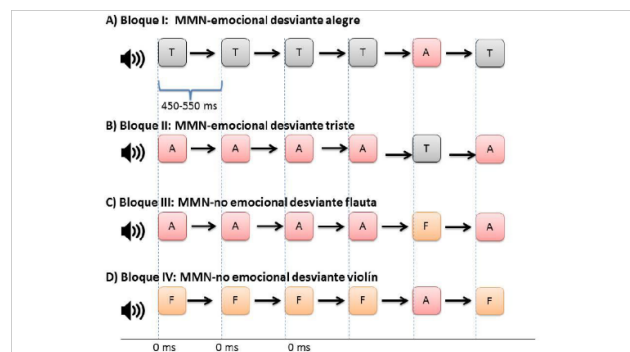


Figura 1.4: MMN Emocional.




Figura 1.5: Moving Dots.

Por último, la siguiente tabla muestra la distribución de muestras de cada clase o etiquetas de grupo por tarea realizada:

Grupos	RS	STB	DBF	MMN	MVD	# sujetos
APS	25	19	16	10	16	30
FEP	16	18	11	0	1	18
EQZ	12	0	2	0	0	10
CNTA	10	9	1	2	8	11
CNTF	36	19	14	15	13	49
Total	100	65	44	27	38	118

Tabla 1.1: Distribución de grupos por tarea y cantidad total de sujetos.

1.3. Procesamiento digital de señales

En la práctica, la adquisición de señales de EEG es susceptible a tener un bajo SNR (signal-to-noise ratio o relación señal/ruido) debido a la alta cantidad de fuentes de ruido captadas por los electrodos, tales como el ruido natural proveniente de la constante actividad cerebral (movimientos musculares, oculares y pensamiento en general), o el ruido externo al cerebro como el ruido electrónico[4].

Para el primer tipo de ruido, uno de los desafíos de la tecnología EEG es que la actividad eléctrica generada por el cerebro es minúscula, del orden de una millonésima de voltio. En consecuencia, la actividad eléctrica registrada en el cuero cabelludo consiste en una combinación de señales cerebrales genuinas combinadas con mucho ruido, denominado artefacto, generado por otras partes del cuerpo, como la actividad cardíaca, los movimientos y parpadeos de los ojos, u otros movimientos de los músculos faciales. producen señales eléctricas unas 100 veces mayores que las producidas por el cerebro. Entonces, una tarea inicial de cualquier análisis de datos de EEG es la eliminación de artefactos, que consiste en separar estas otras señales de las señales emitidas por el propio cerebro. Otra fuente de ruido externo es el entorno en el que se registran los datos de EEG. Las fuentes más comunes de este ruido ambiental son la corriente eléctrica ambiental en cualquier habitación con cableado eléctrico, ya sea 50 o 60 Hz (dependiente del país), y cualquier otro equipamiento eléctrico cercano a los electrodos EEG. Estas señales generalmente se eliminan de la grabación de EEG utilizando un filtro pasabanda que elimina las señales en frecuencias específicas.

Por otro lado, el ruido interno es más complicado puesto que nuestros cerebros están involucrados en muchas actividades diferentes en cualquier momento, y cada una de estas actividades genera una actividad eléctrica que se mezcla con la señal general captada por los electrodos de EEG en el cuero cabelludo. El problema se complica por el hecho de que la actividad siempre ocurre en todo el cerebro, tanto en la superficie cortical cerca del cuero cabelludo como en estructuras profundas del cerebro, y llega al cuero cabelludo de muchas formas diferentes.

La eliminación de ruido de las señales EEG es un proceso importante, ya que si no se separa correctamente la señal EEG del ruido que la rodea, tanto el ruido externo como el interno,

es probable que los resultados sean incorrectos y muy engañosos. Puede parecer que se está produciendo una respuesta en particular, pero si no ha corregido explícitamente la relación señal-ruido (SNR), esa respuesta básicamente no tiene sentido y genera malos resultados para el trabajo que se quiere realizar.

1.4. Extracción de características de las señales

En este contexto, la extracción de características está estrechamente relacionada con el procesamiento de las señales, puesto que un buen procesamiento implica características que puedan representar de mejor manera las muestras de una base de datos. Para las EEG en general, se pueden considerar 3 fuentes principales de información para la extracción de características de señales EEG [5]:

- **Información espacial:** Implica la selección de canales específicos, puesto que estas señales vienen de regiones específicas del cerebro.
- **Información espectral:** Estas características describen variaciones de potencia en bandas de frecuencia específicas.
- **Información temporal:** Uso de valores de señal en ventanas de tiempo diferentes

Estas fuentes son consideradas como las más eficientes para problemas de clasificación, y pueden dividirse en 2 categorías: extracción basada en actividad oscilatoria (espectral y espacial) y extracción basada en potenciales evocados o ERP (temporal y espacial). La primera consiste en un análisis de bandas de frecuencia en los canales que estén relacionados con funciones motoras del cerebro (i.e movimientos de mano y pies, etc.).

El análisis de bandas de frecuencia se basa en que las señales EEG se dividen en 5 tipos de bandas: Delta, Theta, Alfa, Beta y Gamma las cuales tienen determinados rangos de frecuencia (en Hz). Las ondas **Delta** son las que presentan todas las señales por debajo de 4 Hz, y suelen aparecer durante el sueño, en infancia y en enfermedades cerebrales orgánicas serias. La actividad en la banda **Theta** (4-7 Hz) se encuentra en momentos de fase ligera del sueño (quedarse dormido) o estando despierto pero en estado mental profundamente relajado [6]. Las ondas **Alfa** (8-12 Hz) suelen tener mayor actividad en la región occipital durante estados de conciencia sin mayor actividad mental, y es atenuada por estímulos visuales y sensoriales[7]. La actividad de la banda **Beta** (12-30 Hz) se puede dividir en dos: Beta I, relacionada a pensamientos de reflexión (actividad mental baja), y Beta II que aparece durante momentos de actividad mental intensa y tensión. Por último, las ondas **Gamma** (30-60 Hz) es un tipo de banda cuyo estudio es más moderno que las anteriores por lo que aún se desconoce su verdadera naturaleza, pero estudios recientes indican que la actividad en la banda Gamma está relacionada con movimientos oculares rápidos durante el sueño o bien en estados de alta concentración[8].

La segunda en cambio están asociadas con actividad cerebral debido a estímulos específicos percibidos por los pacientes durante las tareas, la cual destaca el ERP P300, que consiste en una amplitud positiva de la EEG al haber pasado 300 milisegundos después de un estímulo que se considera como inusual[5]. Ejemplo de estos estímulos se utilizan en la tarea MMN Emocional, donde se presentan una serie de sonidos separados por pequeños intervalos de tiempo, y luego en un momento determinado se presenta un sonido diferente, conocido como

estímulo desviante.

Otros tipos de extracción de características consisten en no considerar a la señal EEG como una señal específica, sino que en realizar un análisis de series de tiempo general para un intervalo determinado de cada canal. Estas metodologías incluyen [9]:

- Modelamiento por coeficientes regresivos.
- Análisis de potencia en las bandas de frecuencia de las señales y uso de filtro Butterworth para crear un filtro pasabanda.
- Análisis de dimensión fractal, relacionado con entropía o cantidad de información que entrega la señal.
- Selección de canales mediante entropía probabilística y programación genética.

Como se puede notar, existen diversos métodos para extraer características de las señales EEG, los que irán aumentando a medida que se estudien y publiquen más artículos científicos al respecto.

Este trabajo se enfocará, de las metodologías mencionadas anteriormente. en extracción basada en actividad oscilatoria y análisis de series de tiempo. Para ello, se utilizará el lenguaje de programación Python junto a las librerías dedicadas para extracción de características de EEG conocidas como *PyEEG*² y *EntroPy*³. Estas librerías poseen funciones que pueden calcular características de señales de EEG como entropía, dimensión fractal o potencia espectral. En las siguientes subsecciones se estudiarán con mayor detalle estas características.

1.4.1. Intensidad de potencia espectral y Razón de intensidad relativa

Si se considera la señal de EEG como una serie de tiempo $x = [x_1, x_2, \dots, x_N]$ y su transformada de Fourier como $X = [X_1, X_2, \dots, X_N]$, y tomando en cuenta las distintas bandas de frecuencia de las señales EEG: Delta (0.5-4 Hz), Theta (4-7 Hz), Alpha (7-12 Hz), Beta (12-30 Hz) y Gamma (30-60 Hz), entonces al dividir un espectro continuo de frecuencias en K intervalos formando un vector de bandas: $[f_1, f_2, \dots, f_k] = [0, 5, 4, 7, 12, 30, 60]$, se tiene la definición de intensidad de potencia espectral (PSI [10], por sus siglas en inglés) del intervalo k como:

$$PSI_k = \sum_{i=|N(f_k/f_s)|}^{|N(f_{k+1}/f_s)|} |X_i|, \quad k = 1, 2, \dots, K - 1 \quad (1.1)$$

Donde f_s es la frecuencia de muestreo y N el largo de la señal EEG. Luego, en función de PSI se define la razón de intensidad relativa (RIR) como:

$$RIR_j = \frac{PSI_k}{\sum_{k=1}^{K-1} PSI_k}, \quad j = 1, 2, \dots, K - 1 \quad (1.2)$$

²PyEEG: <http://pyeeg.sourceforge.net/>

³EntroPy: <https://raphaelvallat.com/entropy/build/html/index.html>

1.4.2. Dimensión fractal

La dimensión fractal tiene relación con la entropía y la entropía tiene relación directa con la cantidad de información de una señal. La dimensión fractal puede interpretarse simplemente como el grado de serpenteo (rugosidad o irregularidad) en una señal [9].

Método Petrosian

En el método Petrosian de dimensión fractal consiste en convertir la señal EEG a una representación binaria según distintos métodos. Por ejemplo, en el método denominado método *a* se les asigna 1 a los valores sobre el valor promedio de la señal, y 0 en caso contrario. El valor de dimensión fractal de la serie binaria se calcula de la siguiente forma: [11]

$$PFD = \frac{\log_{10} N}{\log_{10} N + \log_{10} \frac{N}{N+0,4N_\delta}} \quad (1.3)$$

Donde N es el largo de la señal original, y N_δ es el número de cambios de signo (0 a 1 y viceversa) de la secuencia binaria.

Método Higuchi

A partir de una serie $[x_1, x_2, \dots, x_N]$ [12], se construyen k series de tiempo x_m^k definidas como:

$$x_m^k = [x(m), x(m+k), x(m+2k), \dots, x(m + \lfloor \frac{N-m}{k} \rfloor k)] \quad (1.4)$$

Con $m = 1, 2, \dots, k$ el tiempo inicial y k el retraso entre los puntos. Para cada serie x_m^k , el largo promedio $L_m(k)$ se obtiene como:

$$L_m(k) = \frac{(N-1) \sum_{i=1}^{\lfloor \frac{N-m}{k} \rfloor} |x(m+ik) - x(m+(i-1)k)|}{\lfloor \frac{N-m}{k} \rfloor k} \quad (1.5)$$

Donde N es el largo de la señal original y $(N-1)/\lfloor \frac{N-m}{k} \rfloor k$ un factor de normalización. El largo promedio total $L(k)$ se calcula para todas las series de tiempo con el mismo retraso k pero distinto m como:

$$L(k) = \sum_{m=1}^k L_m(k) \quad (1.6)$$

Este procedimiento se repite para $k = 1, \dots, k_{max}$, el largo promedio total para el retraso k , $L(k)$, es proporcional a k^{-D} , con D la dimensión fractal del método de Higuchi.

Método Katz

El método Katz se define como [13]:

$$K = \frac{\log_{10}(n)}{\log_{10}(d/L) + \log_{10}(n)} \quad (1.7)$$

Donde L es el largo de la serie de tiempo y d la distancia Euclidiana entre el primer punto de la serie y el punto que proporciona la mayor distancia con respecto al primer punto.

1.4.3. Parámetros de Hjorth

Para una serie de tiempo $x = [x_1, x_2, \dots, x_N]$ se definen la movilidad y complejidad de Hjorth [14] de la siguiente forma:

$$Mobility = \sqrt{\frac{\sum_i (x_i - x_{i-1})/N}{\sum_i x_i/N}} \quad (1.8)$$

$$Complexity = \sqrt{\frac{\sum (x_i - 2x_{i-1} + x_{i-2})/N \cdot \sum x_i/N}{(\sum (x_i - x_{i-1})/N)^2}} \quad (1.9)$$

Los parámetros de Hjorth son descriptores de caída normalizadas (NSDs) usados en EEG para la extracción de características.

1.4.4. Entropía espectral

La entropía espectral se utiliza para cuantificar las irregularidades de una señal de EEG y se define en términos de la razón de intensidad relativa RIR [15]:

$$H = -\frac{1}{\log K} \sum_{i=1}^K RIR_i \log RIR_i \quad (1.10)$$

1.4.5. Entropía de permutación

La entropía de permutación es una medida de complejidad de las series de tiempo introducido por primera Bandt y Pompe en 2002[16]. Sea la serie temporal definida por $\{x_t\}_{t=1\dots T}$. Se estudian todas las $n!$ permutaciones de π de orden n que se consideran como posibles tipos de orden de n números diferentes. Para cada π se determina su frecuencia relativa o probabilidad como:

$$p(\pi) = \frac{\#\{t|0 \leq t \leq T - n, (x_{t+1}, \dots, x_{t+n}) \text{ es de tipo } \pi\}}{T - n + 1} \quad (1.11)$$

Esto estima la frecuencia de π lo mejor posible para una serie finita de valores. Para determinar exactamente $p(\pi)$, se debe asumir una serie infinita $\{x_1, x_2, \dots\}$ y tomar el límite cuando $T \rightarrow \text{inf}$ en la formula anterior. Este límite existe con probabilidad 1 cuando el proceso estocástico subyacente cumple una condición de estacionariedad muy débil: para $k \leq n$, la probabilidad for $x_t < x_{t+k}$ no debería depender de t . Esta se define como:

$$H = -\sum p(\pi) \log_2 p(\pi) \quad (1.12)$$

Donde la sumatoria recorre todas las $n!$ permutaciones de π de orden n . Esta es la información contenida al comparar n valores consecutivos de la serie de tiempo.

1.4.6. Entropía SVD

Se define la entropía por valor singular de descomposición (SVD) [17] para una señal $x = [x_1, x_2, \dots, x_N]$ como una medida de complejidad de secuencias de datos como los son las señales de EEG. Para calcularla, se deben construir vectores de atraso definidos como:

$$y(i) = [x_i, x_{i+\tau}, \dots, x_{i+d_{E-1}\tau}] \quad (1.13)$$

Donde τ es el atraso y d_E la dimensión de incrustación. Luego el espacio de incrustación se define en términos de los vectores de atraso como:

$$Y = [y(1), y(2), \dots, y(N - (d_E - 1)\tau)]^T \quad (1.14)$$

El algoritmo SVD se aplica a la matriz Y para producir M valores singulares $\sigma_1, \dots, \sigma_M$ conocidos como el espectro singular. Dado esto, la entropía SVD se define de la siguiente forma:

$$H_{\text{SVD}} = - \sum_{i=1}^M \bar{\sigma}_i \log \bar{\sigma}_i \quad (1.15)$$

Donde $\bar{\sigma}_i$ son los valores singulares normalizados según $\bar{\sigma}_i = \sigma_i / \sum_{j=1}^M \sigma_j$.

1.4.7. Información de Fisher

La información de Fisher [18], al igual que la entropía SVD, se define en función del espectro singular y es otra medida para cuantificar la complejidad de una señal:

$$FI = \sum_{i=1}^{M-1} \frac{(\bar{\sigma}_{i+1} - \bar{\sigma}_i)^2}{\bar{\sigma}_i} \quad (1.16)$$

1.4.8. Análisis de fluctuación sin tendencia

El análisis de fluctuación sin tendencia (Detrended fluctuation analysis, DFA) es un método para determinar la autoafinidad estadística de una señal. Para una serie $x = [x_1, x_2, \dots, x_N]$ se calcula de la siguiente forma [19]:

1. Primero se integra x para obtener una nueva serie $y = [y(1), \dots, y(N)]$, donde $y(k) = \sum_{i=1}^k (x_i - \bar{x})$, con \bar{x} el promedio de x .
2. La serie integrada se separa en intervalos de igual tamaño n . En cada intervalo, una línea de mínimos cuadrados es ajustada a los datos, representando la tendencia en ese intervalo. La coordenada y de los segmentos de línea recta se denota por $y_n(k)$.
3. La fluctuación media cuadrática de la serie integrada se calcula mediante $F(n) = \sqrt{(1/N) \sum_{k=1}^N (y(k) - y_n(k))^2}$, donde $y(k) - y_n(k)$ se le llama tendencia (detrending).
4. La fluctuación se define como la pendiente relacionando $\log F(n)$ con $\log n$.

1.5. Selección de canales de las señales

Es probable que para resolver el problema de clasificación de psicosis no se tengan que utilizar todos los canales de las señales de EEG, ya que es posible que algunos canales aporten mayor cantidad de información que otros. Para resolver esta problemática se utilizara el algoritmo de **entropía aproximada** (ApEn), la cual es una técnica estadística utilizada para cuantificar la cantidad de regularidad y la impredecibilidad de las fluctuaciones sobre los datos de series

temporales [20]. La presencia de patrones repetitivos de fluctuación en una serie de tiempo la hace más predecible que una serie de tiempo en la que dichos patrones están ausentes. ApEn refleja la probabilidad de que patrones similares de observaciones no sean seguidos por observaciones similares adicionales [21]. Una serie de tiempo que contiene muchos patrones repetitivos tiene un ApEn relativamente pequeño; un proceso menos predecible tiene un ApEn más alto. En la práctica, esto quiere decir que los canales que tengan un mayor valor de ApEn tienden a ser menos impredecibles por lo que aportan una mayor cantidad de información del sistema que los canales con menor ApEn. La entropía aproximada se calcula de la siguiente forma [20]:

1. Sea la señal de entrada $[u_1, u_2, \dots, u_N]$.
2. Sea m entero, y r un positivo real. EL valor de m representa la longitud de la observación de datos comparada, y r representa el orden del filtro.
3. Se construye la subsecuencia $[x_1, x_2, \dots, x_{N-m+1}]$, en \mathbb{R}^m , definido por:

$$x(i) = [u(i), u(i+1), \dots, u(i+m-1)] \quad (1.17)$$

4. Usar la secuencia $x(1), x(2), \dots, x(N-m+1)$ para construir, para cada i , $1 \leq i \leq N-m+1$:

$$C_i^m(r) = (\text{número de } x(j) \text{ tal que } d[x(i), x(j)] \leq r) / (N-m+1) \quad (1.18)$$

Donde se define $d[x, x^*]$ como:

$$d[x, x^*] = \max_a |u(a) - u^*(a)| \quad (1.19)$$

Los $u(a)$ son los m componentes escalares de x . d representa la distancia entre los vectores $x(i)$ y $x(j)$ dada por la diferencia máxima en sus respectivos componentes escalares. Notar que j toma todos los valores, por lo que el par $i = j$ también será contado.

5. Se define:

$$\Phi^m(r) = (M-n+1)^{-1} \sum_{i=1}^{N-m+1} \log(C_i^m(r)) \quad (1.20)$$

6. Se define la entropía aproximada como:

$$\text{ApEn} = \Phi^m(r) - \Phi^{m+1}(r) \quad (1.21)$$

Las ventajas de utilizar el algoritmo de entropía aproximada es que es de baja complejidad computacional y no es afectado de mayor manera por el ruido de la señal. Sin embargo, el algoritmo es dependiente del largo de las señales ya que, en señales de gran tamaño, como las muestras de EEG aquí estudiadas, el tiempo de ejecución del algoritmo ApEn es considerablemente alto.

1.6. Clasificación de psicosis y selección de características

Para poder realizar una clasificación de los datos, las características de las señales extraídas anteriormente, en general, deben estar representadas como un vector de valores numéricos, también conocido como vector de características. Estos vectores de características representan a una muestra de la base de datos en su totalidad, por lo que pueden ser utilizados para entrenar modelos de clasificación utilizando herramientas de aprendizaje de máquinas, también conocidas como Machine/Deep Learning.

En general, la clasificación de datos se realiza utilizando algoritmos especializados de Machine Learning, tales como las librerías *sk-learn* del software de programación Python. La metodología teórica general para la clasificación de datos corresponde a:

1. **Etiquetar vectores de características:** Usualmente los programas computacionales trabajan de mejor manera con números, por lo que es conveniente asignar las muestras de cada paciente a valores numéricos, por ejemplo: Grupos de Control (juntos) se les asigna el valor 0, APS = 1, FEP = 2, y EQZ = 3. Este proceso también se denomina asignación de clases o etiquetas.
2. **Asignar conjuntos de entrenamiento, validación y prueba:** Esta etapa requiere la división de la base de datos en 3 conjuntos:
 - **Entrenamiento:** Permite establecer los parámetros para poder entrenar un modelo de clasificación o clasificador. De esta forma, el conjunto de entrenamiento sirve para establecer como un computador puede procesar la información que se le entrega.
 - **Validación:** Este conjunto sirve para establecer los hiperparámetros de un clasificador. Los hiperparámetros son parámetros o valores que son propios de la arquitectura de un clasificador. Por ejemplo, la cantidad de neuronas y capas ocultas de una red neuronal artificial.
 - **Prueba:** Se utiliza netamente para determinar el rendimiento del clasificador. Generalmente la cantidad de muestras en el conjunto de prueba debe ser igual a la del conjunto de validación. No debe ser utilizado para el entrenamiento y ajuste del clasificador.

La distribución probabilística de estos conjuntos debe ser idealmente igual para los 3, es decir, las proporciones de las clases en los conjuntos debe ser idéntica a las proporciones de los conjuntos con respecto a la base de datos. Por ejemplo, si en la base de datos para la tarea Resting State se tienen 25 APS, 16 FEP, 8 EQZ y 46 Control. Si uno quisiera dividir la base de datos en 60 % entrenamiento, 20 % validación y 20 % prueba, en los datos de entrenamiento se tendrían: las siguientes muestras: 15 APS, 10 FEP, 4 EQZ y 28 Control, manteniendo la relación tanto entre conjuntos como entre las clases.

3. **Elección de un clasificador:** Una vez se tienen los conjuntos para entrenar, ajustar y probar los modelos de clasificación, ahora se procede a elegir el tipo de clasificador a utilizar. Las técnicas más utilizadas en la literatura [22][23] para la clasificación de

EEG son Multi-Layer Perceptron (redes neuronales básicas), Redes Recurrentes, Redes Convolucionales, Support Vector Machine y Linear Discriminant Analysis.

4. **Análisis de rendimiento de clasificador:** Luego de entrenar y ajustar un clasificador con los conjuntos previamente mencionados, se procede a evaluar el conjunto de prueba en el modelo de clasificación obteniendo de esta forma etiquetas de predicción para este conjunto. Luego, se comparan las etiquetas de predicción con las etiquetas actuales del conjunto de prueba obteniendo lo que se conoce como matriz de confusión:

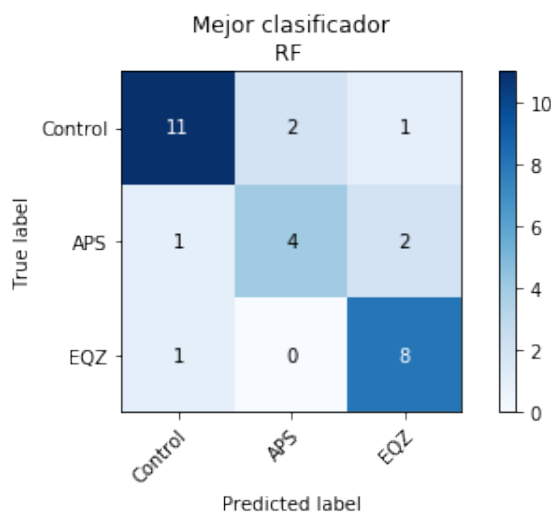


Figura 1.6: Ejemplo de matriz de confusión para 3 clases

Calcular la traza de la matriz, es decir, la suma de los elementos de la diagonal, dividida por el total de muestras en el conjunto de prueba entrega la precisión del clasificador. Para los problemas de clasificación binarios también es válido analizar el rendimiento de cada clase por separado, definiendo los conceptos de sensibilidad, como la capacidad para detectar casos que realmente padecen la enfermedad y la especificidad como la capacidad para detectar casos que realmente sean pacientes sanos.

5. **Validación cruzada aleatoria:** Para validar el modelo de clasificación, se utilizará una técnica conocida como validación cruzada aleatoria (Repeated random sub-sampling validation). Este método, también conocido como validación cruzada de Monte Carlo [24], crea múltiples divisiones aleatorias del conjunto de datos en conjuntos de entrenamiento y prueba [25]. Para cada división, el modelo se ajusta a los datos de entrenamiento y la precisión predictiva se evalúa utilizando los datos de prueba. Los resultados se promedian sobre las divisiones. La ventaja de este método es que la proporción de la división de entrenamiento / validación (prueba en este caso) no depende del número de iteraciones (es decir, el número de particiones). La desventaja de este método es que algunas observaciones nunca pueden seleccionarse en la submuestra de validación, mientras que otras pueden seleccionarse más de una vez. En otras palabras, los subconjuntos de validación pueden superponerse. Este método también exhibe la variación de Monte Carlo, lo que significa que los resultados variarán si el análisis se repite con diferentes divisiones aleatorias.

Realizando este procedimiento de forma independiente para las tareas realizadas por los pacientes permite determinar cuáles son las combinaciones óptimas de procesamiento, extracción de características y clasificadores que maximicen la precisión del modelo de clasificación. Por último, para disminuir el costo computacional del problema (tiempo de procesamiento del algoritmo) y su variación en los resultados de clasificación se deberá realizar un proceso de selección de características, para así filtrar las características que no entreguen información útil al modelo.

Capítulo 2

Metodología

2.1. Ajustes de bases de datos

Teniendo en cuenta los datos de la tabla 1.1, es importante destacar que la cantidad de sujetos por grupo fue variable en cada tarea realizada. Por ejemplo, de los 30 pacientes etiquetados como APS, 25 realizó la prueba Resting State mientras que solo 19 fue sometido a Sternberg, por lo que es necesario estudiar las señales de cada tarea de forma independiente. Por lo demás, las tareas MMN y Moving Dots no presentan muestras de pacientes con esquizofrenia o FEP. Además, la primera muestra APS de Resting State fue eliminada debido a que tenía una duración de 400 segundos, mientras que las demás duraban en promedio 240 segundos que corresponden a los 4 minutos totales de medición para Resting State. Por lo tanto, en el conjunto Resting State se tendrán 99 muestras en lugar de 100. Algo similar ocurre para el conjunto STB, donde en lugar de 65 muestras se tendrán 64.

Cabe destacar que el conjunto que será utilizado para un análisis más exhaustivo será el de Resting State, puesto que es el conjunto con mayor cantidad de muestras y además es el de menor tamaño computacional (en bytes) comparado con el resto de los conjuntos. Realizando pruebas sobre este conjunto permite generalizar de mejor forma las metodologías realizadas. Por otro lado, también se realizarán pruebas utilizando el conjunto Double Flash, Sternberg, Moving Dots y MMN, los cuales contienen menos muestras, pero mayor cantidad de información (en largo y bytes) que Resting State por lo cual se obtuvieron diferentes resultados de clasificación para cada conjunto.

Para poder observar y procesar señales de EEG se utilizará la librería EEGLAB¹ la cual puede instalarse en el software de programación MATLAB. Estas señales se encuentran en formato Biosemi o BDF y presentan altos niveles de ruido, lo que hace su procesamiento una necesidad. La obtención de las señales EEG se realizó mediante el uso de un casco con 72 electrodos lo que se traduce a señales de 72 canales por muestra, de los cuales 64 son de electroencefalograma y 8 de electrooculograma. Una representación general de la posición y denominación de los electrodos en el cuero cabelludo es la siguiente:

¹EEGLAB <https://sccn.ucsd.edu/eeglab/index.php>

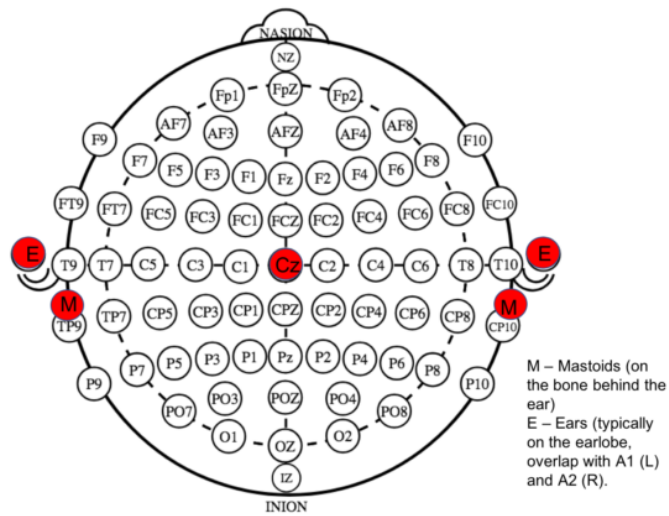


Figura 2.1: Distribución general de electrodos en cuero cabelludo.

Los archivos con las señales cerebrales captadas por cada uno de los 72 electrodos se pueden observar en EEGLAB, resultando en el siguiente gráfico:

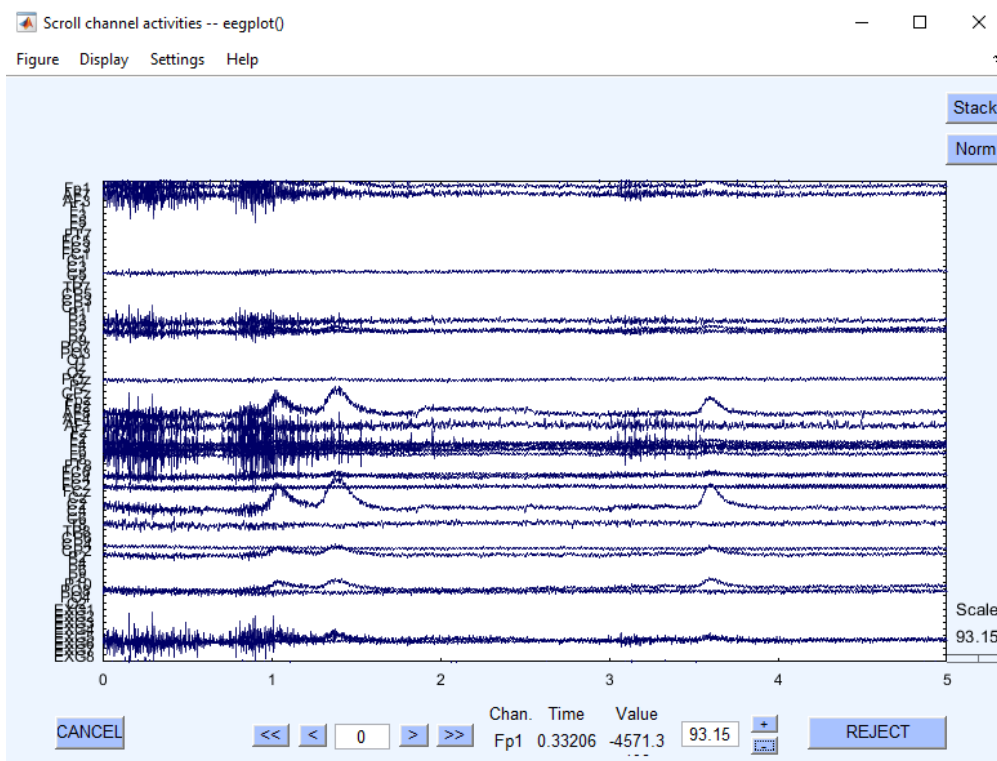


Figura 2.2: Ejemplo de señal de EEG

La señal cruda (sin procesar) de este ejemplo corresponde a una muestra APS de la tarea Resting State. Se puede apreciar la alta presencia de ruido electrónico y componentes innecesarias de la señal. Es importante mencionar que algunas muestras se encuentran fragmentadas

en archivos de menor tamaño, por lo fue necesario crear un algoritmo en Matlab que pueda reconstruir las muestras completas, concatenando los archivos pequeños en uno de mayor tamaño.

2.2. Procesamiento digital de señales

Para eliminar el ruido y componentes innecesarias de las señales, también conocidos como artefactos, se utilizarán herramientas existentes tanto en funciones de procesamiento de señales de EEGLAB², como funciones nativas de Matlab.

2.2.1. Filtrado pasabanda

Para eliminar las componentes innecesarias en frecuencia de las señales mediante filtrado pasabanda, se utilizará el filtro digital de fase cero de Matlab y el filtro de EEGLAB, que es un filtro de respuesta finita al impulso (FIR filter). La utilización de estos dos tipos distintos de filtros se debe a que el filtro de EEGLAB puede escoger automáticamente el orden de filtrado mediante métodos de heurística logrando mejores resultados, pero esto puede implicar en un mayor costo computacional y por ende mayor tiempo de procesamiento al tener filtro de mayor orden. Por otro lado, el filtro de fase cero de Matlab ayuda a preservar las características en una forma de onda de tiempo filtrada exactamente donde ocurren en la señal sin filtrar (i.e. no hay diferencias de fase), pero el orden del filtro debe ser definido por el usuario dentro de la función de diseño de filtros Butterworth, puesto que esta última también define los parámetros de la función de transferencia del filtro de Matlab. Como el usuario en este caso es capaz de elegir el orden de filtro, se puede conseguir una mejor velocidad de procesamiento de las señales en desmedro de un procesamiento más profundo. Para ambos casos, el rango de frecuencias de los filtros pasabanda será de 0.5 a 60 Hz, el cual contiene bandas de frecuencias específicas de las señales EEG conocidas como las bandas Delta, Theta, Alpha, Beta y Gamma, cuyas características serán explicadas en la siguiente sección.

2.2.2. Reducción de frecuencia de muestreo

Dado que la frecuencia de muestreo con la cual se obtuvo cada señal es alta, de 2048 Hz, las diferencias temporales entre cada valor numérico (voltaje cerebral) de una señal son pequeñas lo que deriva en señales de gran tamaño, provocando un alto costo computacional para procesar las señales. Para disminuir las frecuencias de muestreo de las señales se utilizará una función de EEGLAB para volver a muestrear los datos con el fin de reducir la frecuencia de muestreo a 256 Hz. Como caso especial, también se realizarán experimentos para las bases de datos Resting State y Double Flash a 128 Hz con el fin de comparar resultados de clasificación y analizar rendimiento, puesto que al tener señales de tamaño reducido mejora los tiempos de ejecución de algoritmos. Es importante destacar que al reducir la frecuencia de las señales se están eliminando componentes temporales que pueden o no ser importantes para la posterior extracción de características de las señales.

²https://sccn.ucsd.edu/wiki/Chapter_04:_Preprocessing_Tools

2.2.3. Eliminación de artefactos

La eliminación de artefactos de las señales se efectúa utilizando conjuntamente el algoritmo ICA de EEGLAB y la herramienta adicional de EEGLAB conocida como Adjust³. El algoritmo de descomposición de datos ICA o Independent Component Analysis consiste en la elección de filtros de componentes independientes para producir señales independientes temporalmente máximas disponibles en los datos del canal. Estas corresponden a fuentes de información en los datos cuyas mezclas se han registrado en los canales del cuero cabelludo.

El proceso de mezcla (para EEG, por conducción de volumen) es pasivo, lineal y no agrega información a los datos. Por el contrario, mezcla y oscurece las contribuciones de fuente funcionalmente distintas e independientes. Estas fuentes de información pueden representar actividad sincrónica o parcialmente sincrónica dentro de un(os) parche(s) cortical(es), de lo contrario, actividad de fuentes no corticales como por ejemplo potenciales inducidos por movimientos del globo ocular o producidos por actividad de un solo músculo, ruido de línea, entre otros[26].

Luego de ejecutar el algoritmo ICA sobre los canales de las señales, se ejecuta el algoritmo Adjust para identificar los artefactos con componentes independientes, tales como: pestaños, movimientos oculares y/o musculares y discontinuidades genéricas. Una vez identificados estos artefactos, simplemente se eliminan de la señal dejando la actividad causada por las fuentes neuronales sin cambios[27].

Finalmente, cabe destacar que el orden en que se efectúan estos algoritmos, o su ausencia, en el procesamiento de señales puede influir en los resultados de clasificación finales. Por lo que se realizarán análisis para diferentes ordenes de procesamiento sobre los conjuntos de señales, las cuales serán detalladas en la sección de Desarrollo.

2.3. Extracción de características

Como se mencionó en la sección 1.4, se utilizará el lenguaje de programación Python junto a las librerías dedicadas para extracción de características de EEG conocidas como *PyEEG* y *EntroPy*, cuyas funciones de análisis de series de tiempo fueron definidas anteriormente. La metodología de extracción consiste en la obtención de las intensidades de poder espectral y razón de intensidad relativa para las 5 bandas de frecuencia de las EEG (Delta, Theta, Alpha, Beta, Gamma), utilizar 3 técnicas de dimensión fractal (Petrosian, Higushi, Katz), 2 parámetros de Hjorth (movilidad y complejidad), 3 medidas de entropía (espectral para 5 bandas de frecuencia, permutación de orden 5 y SVD de orden 5), información de Fisher, y finalmente análisis de fluctuación de tendencia, llegando a un total de 20 características que serán extraídas para cada canal (72) de una muestra de las bases de datos.

Además, se realizará la metodología de selección de canales usando el concepto de entropía aproximada (ApEn) para disminuir las dimensiones de los vectores de características y realizar un análisis comparativo de resultados para la totalidad de los canales, 54 canales, 36 canales, 18 canales y 6 canales seleccionados.

³<https://www.nitrc.org/projects/adjust/>

2.4. Clasificación de psicosis y análisis de características

Como bien se mencionó en la sección 1.6, se utilizarán las herramientas de aprendizaje de máquinas disponibles en la librería *sklearn* del software de programación Python. El primer paso corresponde a etiquetar numéricamente las muestras de las bases de datos según el grado de psicosis que representen, lo que además depende de la cantidad de muestras presentes en una determinada base de datos. Como la base de datos Resting State es la que tiene mayor cantidad y diversidad de pacientes, será posible plantear sistemas de clasificación binarios como: Control vs Esquizofrenia, Control vs Psicosis o Control adolescente vs APS, también sistemas de 3 clases y sistemas de 5 clases. Las otras bases de datos, al tener cantidades reducidas de muestras, serán planteadas en problemas de clasificación binarios de forma general. Estos conjuntos se verán con más detalle en el capítulo 4.

Antes de separar las bases de datos en los conjuntos de entrenamiento y validación (prueba), primero se normalizarán las muestras de las bases de datos de forma que tengan media 0 y varianza unitaria mediante la función *StandardScaler()*, esto demostró ser útil para la obtención de mejores resultados. Como en este caso se tiene una base de datos con muestras completamente etiquetadas, solo basta contar con los conjuntos de entrenamiento y validación, cuya relación en todos los experimentos será de 70 % y 30 %, respectivamente, puesto que tener un conjunto de prueba y validación sería redundante y disminuiría la cantidad de datos a entrenar y evaluar.

En cuanto a clasificadores, para este trabajo se utilizará un clasificador basado en árboles de decisión conocido como RandomForest (RF), un clasificador basado en arboles de regresión llamado GradientBoosting (GB), el clasificador probabilístico Linear Discriminant Analysis (LDA), y clasificadores clásicos de aprendizaje supervisado como lo son K-Nearest Neighbors (KNN), Multi-Layer Perceptron (MLP) y Support Vector Machine (SVM). Se decidió por utilizar estos clasificadores debido a que son comunes en la resolución de problemas de clasificación y pueden entregar resultados distintos dependiendo del tipo de problema que se quiera resolver.

Debido a que existe una alta variabilidad al tener diferentes combinaciones de conjuntos de entrenamiento y validación, como se mencionó anteriormente se utilizará la validación cruzada de Monte Carlo para generar 50 combinaciones aleatorias de conjuntos de entrenamiento y validación, para finalmente obtener 50 resultados distintos de precisión los cuales se promediarán para obtener un único resultado. Logrado esto, se realizará el proceso de selección de características usando herramientas del software libre de Machine Learning de la Universidad de Waikato conocido como WEKA⁴. Al tener menos características que procesar, se aumentará el número de iteraciones de Monte Carlo de 50 a 500, puesto que una mayor cantidad de iteraciones permite obtener una mejor generalización de los resultados de clasificación.

Para finalizar, se realizará un análisis clínico y técnico de las características seleccionadas por WEKA, con el fin de relacionar estas características con la actividad cerebral y la posición de los electrodos EEG. Esto se hará mediante un análisis manual, uso de histogramas y un mapa de electrodos, para determinar cuáles son las características que más se repiten y en que canal se ubica para asociarlas a los lóbulos cerebrales.

⁴Waikato Environment for Knowledge Analysis <https://www.cs.waikato.ac.nz/ml/weka/>

Capítulo 3

Revisión Bibliográfica

En esta sección se revisarán metodologías realizadas por la comunidad científica que plantean soluciones al problema de clasificación de psicosis y/o similares, enfocándose en las metodologías de extracción de características.

En el artículo *A new approach for EEG signal classification of schizophrenic and control participants*[9], mediante distintas técnicas de extracción de características se lograron buenos resultados para el problema de clasificación binario de esquizofrenia y grupos de control. Para ello, se tomaron 20 participantes entre 18 y 55 años para el grupo de control y 20 pacientes entre 20 y 53 años con esquizofrenia. Cada paciente y participante fue sometido a una prueba de quedarse 2 minutos con los ojos abiertos (Resting State) donde se utilizaron 24 canales de electrodos para capturar señales cerebrales mediante EEG. Para extraer características de estas señales, se dividieron en ventanas de tiempo de 1 segundo para asumir una aproximación estacionaria en las señales, puesto que la señal EEG completa es una serie de tiempo no estacionaria. Luego se utilizaron 3 métodos de extracción de características para cada ventana:

1. Coeficientes autorregresivos: El modelo de CA es una poderosa herramienta utilizada para el modelado de señales. En este modelo, cada muestra se considera una predicción de muestras ponderadas anteriores. El número de pesos (coeficientes) determina el orden del modelo. En este artículo se utiliza el algoritmo de Burg.
2. Bandas de potencia: Para la estimación potencia en las bandas (delta, theta, alfa y beta), se estima la potencia promedio en cuatro bandas en cada posición del electrodo. Esto se logra filtrando primero los datos en los rangos de frecuencia estándar usando un filtro de paso de banda digital (Butterworth de orden cinco).
3. Dimensión fractal: La dimensión fractal tiene una relación con la entropía y la entropía está directamente relacionada con la cantidad de información dentro de una señal. La dimensión fractal puede interpretarse simplemente como el grado de serpenteo (aspereza o irregularidad) en una señal. Aquí, se presentan tres métodos de cálculo de la dimensión fractal: método Higushi, método Katz y método Petrosian.

En total se tendrían 300 características: 15 características para cada canal (8 para CA, 4 para bandas de potencia y 3 para dimensión fractal). Luego de extraer características de las señales se realiza el proceso de selección de canales basándose en el criterio de entropía e información mutua, el cual consiste en utilizar funciones de densidad de probabilidad de las variables del sistema, resultando en la elección de 20 canales. Para optimizar el algoritmo de clasificación, se debe realizar un proceso de selección de características, para esto se utiliza un algoritmo conocido como programación genética, el cual es una búsqueda estocástica que imita la evolución biológica natural. En cada generación, se crea un nuevo conjunto de aproximaciones mediante el proceso de selección de individuos de acuerdo con su nivel de aptitud física y su reproducción mediante operadores adoptados a partir de genética natural. Las características seleccionadas se redujeron a 65 para clasificador Linear Discriminant Analysis (LDA) y 85 para AdaBoost, obteniendo los siguientes resultados:

Table 4
Test results by different classifiers to discriminate schizophrenic and normal participants.

Different classifiers		Sensitivity	Specificity	Accuracy
LDA	The proposed approach	0.8645	0.8529	0.8590
	PCA-based feature selection	0.7986	0.8061	0.8022
Adaboost	The proposed approach	0.9291	0.9057	0.9194
	PCA-based feature selection	0.8330	0.8722	0.8493

Figura 3.1: Resultados de clasificación.

Donde en ambos clasificadores se obtuvieron buenos resultados, con AdaBoost por sobre LDA. En este caso, dado que se trata de un problema de clasificación binario es importante definir los conceptos de sensibilidad y especificidad. La sensibilidad mide el porcentaje de pacientes esquizofrénicos correctamente clasificados mientras que la especificidad es el porcentaje de grupo de control correctamente clasificado. Es importante destacar que la extracción de características mediante programación genética se comparó a una ya existente usando el algoritmo Principal Component Analysis (PCA) como se puede ver en la tabla de resultados. En general este artículo presenta la mayor parte del trabajo que se quiere hacer en esta memoria, pero sus limitaciones son tener que dividir las señales en ventanas de 1 segundo y la falta de análisis en la selección de los canales EEG. Las metodologías planteadas en esta memoria se basan en la extracción de características de una señal completa, sin tener que fragmentar la señal en intervalos más pequeños y por ende aumentar la cantidad de características. También se realizará selección de canales mediante cálculo de entropía o cantidad de información en cada canal. Por otro lado, en esta memoria se demostrará que existen mejores métodos de selección de características que programación genética, llegando a reducir la cantidad de características en aproximadamente un 98 %.

El artículo *EEG Classification During Scene Free-Viewing for Schizophrenia Detection*[23] escrito por académicos de la Facultad de Medicina de la Universidad de Chile trata sobre clasificación de grupos de control y pacientes con esquizofrenia utilizando el potencial evocado P500. La base de datos consistía en señales de EEG con 32 canales y señales de electrooculograma (EOG) de 6 canales de 11 pacientes con esquizofrenia y 9 personas

en grupo de control. Los sujetos realizaron una tarea visual de exploración libre en la que escanearon imágenes presentadas en una pantalla mientras se grababan EEG y movimientos oculares. La tarea de exploración libre consistió en imágenes en escala de grises de diferentes categorías: paisajes (o escenas naturales, NS), sitios de construcción, fractales y ruido rosa (PN), ruido blanco, imágenes uniformemente en gris y negro. Cada categoría tenía un total de 10 imágenes diferentes. Se eligió ruido rosa e imágenes en gris liso para controlar las propiedades físicas de las imágenes del paisaje, específicamente la luminosidad y el contenido espectral. Estas tres categorías de imágenes fueron suficientes para abarcar los aspectos físicos y cognitivos de una imagen. El procesamiento de las señales se centró solamente en las épocas en que los sujetos fueron expuestos a las imágenes, donde se hicieron recortes temporales y se aplicó filtro Butterworth entre las frecuencias de 1 y 40 Hz. Para cada prueba se calcularon los potenciales evocados (ERP) en promedio según los canales de EEG presentes en los lóbulos frontal, central, occipital y parietal. De cada uno de estos 4 ERP promedio, se usó la media entre 400 ms y 600 ms como muestra para las estadísticas y como característica para la clasificación.

Para realizar la clasificación de los datos, se utilizaron los clasificadores LDA, un clasificador basado en reglas, y una combinación de la probabilidad posterior de dos LDA. Se realizó un 300 cross-validation con 16 muestras para entrenamiento y 4 para el conjunto de prueba. La comparación de rendimiento de los clasificadores utilizados se realizó mediante la construcción de curvas ROC. Al comparar los ERP obtenidos de las 4 regiones del cerebro se obtuvo que la región occipital era la que presentaba características más significativas para diferenciar pacientes de esquizofrenia con los del grupo de control, de las cuáles son de mayor relevancia las muestras de imágenes con escenas naturales. Los resultados obtenidos fueron los siguientes:

TABLE II
DIAGNOSTIC EFFICIENCY OF EACH CLASSIFIER

Classifier	Ss	Sp	ACC
<i>Fron-NS</i>	0.71	0.09	0.38
<i>Occi-NS</i>	0.79	0.64	0.71
<i>Fron-Occi-NS</i>	0.79	0.60	0.69
<i>All-NS</i>	0.68	0.47	0.58
<i>All-Fix-NS</i>	0.75	0.53	0.64
<i>Fron-PN</i>	0.61	0.08	0.32
<i>Occi-PN</i>	0.56	0.08	0.33
<i>Fro-Occi-PN</i>	0.45	0.08	0.25
<i>All-PN</i>	0.57	0.57	0.57
<i>All-Fix-PN</i>	0.63	0.67	0.65
<i>Fron-Gray</i>	0.61	0.18	0.38
<i>Occi-Gray</i>	0.72	0.23	0.46
<i>Fron-Occi Gray</i>	0.06	0.21	0.04
<i>All-Gray</i>	0.46	0.36	0.41
<i>All-Fix-Gray</i>	0.54	0.35	0.44
<i>Rule Based</i>	0.75	0.68	0.71
<i>Comb-Bin</i>	0.78	0.60	0.69
<i>Comb-Prob</i>	0.81	0.59	0.71

Figura 3.2: Resultados de clasificación para las distintas muestras.

Se puede observar que la mejor precisión obtenida es de 71 % para los clasificadores de combinación probabilística, en base a reglas, y LDA usando imágenes NS en el lóbulo occipital, el cual no es un porcentaje muy alto comparado con el artículo revisado anteriormente, pero utiliza otra metodología de extracción de características de las señales. Como se mencionó anteriormente esta memoria no se enfocará en análisis de ERP, pero al ser ambas bases de

datos obtenidas por la Clínica Psiquiátrica enfocarse en esta memoria en análisis y extracción de características de series de tiempo complementa esta información donde, además, como se verá más adelante, se obtienen mejores resultados que en este caso.

En *EEG Signals Classification Using Machine Learning for The Identification and Diagnosis of Schizophrenia*[28] se plantea la realización de un clasificador basado en aprendizaje de máquinas para la diferenciación de pacientes con esquizofrenia y grupos sanos de control usando características extraídas de EEG basadas en ERP. La base de datos utilizada corresponde a 'EEG data from basic sensory task in Schizophrenia' que se encuentra disponible en línea de forma gratuita en *kaggle* y consiste en potenciales relacionados a eventos (ERP) de señales EEG de 32 personas sanos y 49 pacientes con esquizofrenia, los cuáles fueron sometidos a tareas básicas como presionar botones después de un tono, algo parecida a la prueba Stemberg de la base de datos de esta memoria pero en lugar de estímulo visual el estímulo es auditivo. Por otro lado, se utilizaron 64 canales o electrodos para la obtención de las señales EEG (al igual que esta memoria sin contar EOG) pero solo se utilizaron 9 canales (Fz, FCz, Cz, FC3, FC4, C3, C4, CP3, CP4) para medir promedios ERP. La frecuencia de muestreo de estas señales es de 1024 Hz y pasadas por un filtro pasabanda entre 0.5 y 15 Hz, lo que implica eliminar la banda Beta y Gamma de las señales. Para extraer las características de estas señales primero se remueven los componentes estacionarias y tendencias (artefactos) para no afectar al análisis de las señales, luego el autor establece condiciones en base a si el paciente presionó el botón cuando escuchó un tono (condición 1), presionó el botón sin tono (condición 2), y si escuchó el tono, pero no presionó el botón (condición 3) y estas características se extraen de los ERP N100, P200 y peak-to-peak P300/N100. A estas características también se le añaden factores como el género, edad y educación, por lo que el autor genera 11 conjuntos de características distintos para determinar cuál es el que minimiza el error total de clasificación, la cual se realizará mediante el clasificador Random Forest implementado en lenguaje de programación R. Los resultados de clasificación de Random Forest para distintos conjuntos de características se resumen en el siguiente cuadro:

Feature Combination											
Feature Sets	1	2	3	4	5	6	7	8	9	10	11
Gender	x ¹	x	x	x	x	x	x	x	x	x	x
Age	-	x	x	x	x	x	x	x	x	x	x
Education	x	x	x	x	x	x	x	x	x	x	x
FzN100.min	-	-	x	-	x	x	x	x	x	-	-
FzN100.min.Index	-	-	-	x	x	x	x	x	x	-	-
Fz.peak2peak	-	-	-	-	-	-	-	-	x	x	-
Condition 1,2 &3	-	-	x	x	x	-	-	-	x	-	-
Condition 1 only	-	-	-	-	-	x	-	-	-	-	-
Condition 2 only	-	-	-	-	-	-	x	-	-	-	-
Condition 1 & 2	-	-	-	-	-	-	-	x	-	-	-
Condition 2 & -2 ²	-	-	-	-	-	-	-	-	-	-	x
Class error 0-1 ³	65.63%	53.13%	34.38%	32.29%	34.38%	56.25%	50%	31.25%	31.25%	19.79%	50%
Class error 1-0	14.29%	8.16%	13.61%	10.2%	7.48%	20.41%	14.29%	10.20%	10.20%	9.52%	24.49%
Total error rate	34.57%	25.93%	21.81%	18.93%	18.11%	34.57%	28.4%	18.52%	18.52%	13.58%	34.57%

¹ 'x' indicates selected, '-' indicates unselected.
² Condition 1: button & tone; condition 2: tone only; condition 3: button only; condition -2: subtracting condition 3 from condition 1.
³ '0' indicates healthy control, '1' indicates schizophrenia patient.

Figura 3.3: Resultados de clasificación para distintos conjuntos de características.

Donde los errores clase 0-1 y 1-0 corresponden a falsos positivos (control clasificado como esquizofrénico) y falsos negativos (esquizofrénico clasificado como control), respectivamente.

Finalmente, mediante 10-fold cross-validation con Random Forest se obtuvo una precisión (accuracy) máxima de 81.10%. Dado esto, las limitaciones de este artículo es el uso de solo un clasificador, el uso de una cantidad limitada de canales de EEG, no utilizar extracción de características basadas en información espacial y espectral, y tampoco disponer de una cantidad mayor tareas realizadas por pacientes y de tipos de psicosis. Estas limitaciones serán abordadas a lo largo de este trabajo de título.

En el artículo *Development of a Machine Learning Based Algorithm To Accurately Detect Schizophrenia based on One-minute EEG Recordings*[29] consiste de un trabajo similar al planteado en este memoria, donde se plantea un algoritmo de clasificación de esquizofrenia usando una base de datos de señales EEG de un total de 14 pacientes con esquizofrenia y 14 pacientes de grupo de control, con frecuencia de muestreo de 250 Hz y grabaciones de aproximadamente 15 minutos durante una tarea Resting State con ojos cerrados de 19 canales: Fp1, FP2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1, O2. Para empezar, la eliminación de artefactos y componentes innecesarias de las señales fue realizada mediante el algoritmo ICA, al igual que en esta memoria, pero de la librería *eegkit* para el lenguaje de programación R, mientras que aquí se implementó en Matlab. Estas señales EEG luego se dividieron en fragmentos de un minuto resultando en un total de 499 grabaciones. Usando estas pequeñas señales los autores realizaron extracción de características midiendo 'fuerza' de las transformadas rápidas de Fourier de las señales en 200 bandas de frecuencia donde las señales en los 19 canales se promediaron para obtener solo una señal, pero esto no es explícito en el artículo. Además, se considera 2 conjuntos de características: división 99 bandas con rango de 0.5 Hz, y extensión a 100 Hz para cubrir la banda Gamma. Para clasificar, se utilizó Random Forest de 500 árboles en su implementación en R y se dividió la base de datos procesada de 499 señales en 75% conjunto de entrenamiento (375) y 25% conjunto de prueba (124). Luego se realizó 10-fold cross validation para validar los resultados, y se obtuvo 96.01% de precisión para la primera división de características y 96.77% para la extensión a banda de frecuencia Gamma alta (50-100 Hz). La limitación de esta metodología es que se está clasificando fragmentos de una muestra de la base de datos y no la muestra en sí, lo que implica que para un caso se podrían tener la mitad de los fragmentos clasificados como control y la otra mitad clasificada como esquizofrenia, lo que generaría incertidumbre. Otra limitación es la baja cantidad de muestras originales en la base de datos, ya que tener un total de solo 24 pacientes es insuficiente para realizar un buen clasificador. Tampoco se especifica exactamente como se realizó la extracción de características y lo que se hizo para los 19 canales de EEG. Las técnicas que se realizarán en esta memoria plantean una clasificación de una muestra completa de una base de datos relativamente nueva con tareas Resting State de 100 pacientes y Double Flash de 44 pacientes, lo que resuelve las dos primeras limitaciones, mientras que el trabajo realizado aquí será ampliamente documentado, justificado y de mayor complejidad que el mostrado en el artículo.

En *Machine learning identification of EEG features predicting working memory performance in schizophrenia and healthy adults*[30] se utilizan señales EEG de 40 pacientes con esquizofrenia (SZ) y 12 pacientes de sanos (HC) sometidos a la prueba de memoria Sternberg (SWMT). De estas EEG se extraen 5 componentes en frecuencia (theta1, theta2, alfa, beta, gamma) en 4 etapas de procesamiento (línea de base, codificación, retención, recuperación) y 3 sitios de cuero cabelludo: Fz, Cz y Oz. Se utilizó el clasificador Support Vector Machine para clasificar la precisión de la prueba Sternberg (correcto vs incorrect, Modelo 1) y la clasificación diagnóstica de esquizofrenia (SZ vs HC, Modelo 2). La validez externa de los modelos SVM se examinó en relación con el rendimiento de las pruebas neuro-psicológicas y la clasificación diagnóstica utilizando análisis convencionales basados en regresión. El rendimiento de SWMT se redujo significativamente en SZ. El modelo 1 clasificó correctamente la precisión de los ensayos al 84 % en HC y al 74 % cuando se validaron de forma cruzada en los datos de SZ. La gamma frontal (Fz) en la codificación y la theta central (Cz) en la retención proporcionaron las ponderaciones más altas, representando el 76 % de la variación en las puntuaciones SWMT y la variación del 42 % en el rendimiento de las pruebas neuro-psicológicas en todas las muestras. El modelo 2 identificó theta frontal al inicio y alfa frontal durante la recuperación como clasificadores primarios del diagnóstico, proporcionando una precisión de clasificación del 87 % como función discriminante. Estos son buenos resultados ya que se utiliza Support Vector Machine que es muy utilizado en diversas aplicaciones, pero el problema yace en que no se utilizan las definiciones propiamente tales de las bandas de frecuencia, sino que aproximaciones centradas en un determinado valor. Además, pese a que se utiliza una tarea de memoria, no se utilizan los canales del lóbulo temporal (T), que podrían tener mayor relevancia que los canales centrales, por lo que se está perdiendo información de las EEG. También se tiene que la proporción de las clases no es la indicada, ya que el conjunto de pacientes con esquizofrenia es casi 3 veces mayor que el conjunto de pacientes del grupo de control, lo que no es ideal ya que el sistema se estará sobreajustando a las muestras con diagnóstico esquizofrénico. En este trabajo se planea utilizar todo el espectro de bandas de frecuencia (0.5 a 60 Hz) y más electrodos que los que se utilizaron en este artículo, con la diferencia de que esta vez se utilizarán tareas distintas: Resting State y Double Flash, además de tener una proporción similar tanto para los pacientes con esquizofrenia como grupo de control.

En *An efficient classifier to diagnose of schizophrenia based on the EEG signals*[31] se tienen señales EEG de 13 pacientes con esquizofrenia y 18 pacientes en el grupo de control para la clasificación de ambos conjuntos. Las EEG están conformadas por 22 canales con frecuencia de muestreo de 200 Hz, y se captaron al realizar la mitad de la tarea Resting State sobre los pacientes (2 minutos con ojos abiertos). Se utilizó 3 métodos de extracción de características de estas señales: modelo autorregresivo, bandas de potencia (0.4 a 30 Hz) y dimensión fractal (Higuchi, Katz y Petrosian). Al igual que en otros artículos se asume señal no estacionaria por lo que se dividen en ventanas de 2 segundos para asumir señales estacionarias. Luego, los clasificadores utilizados consisten en variaciones de LDA (FLDA y BDLDA) y AdaBoost, y se utilizaron las señales EEG con 50 % de traslape para extraer características de todos los canales y cada ventana, usando *leave-one-out cross validation* para validar los resultados, que consiste en probar con solo 1 muestra y entrenar los clasificadores con las muestras restantes. Se calculó la precisión promedio y la desviación estándar de los resultados, obteniendo una precisión promedio máxima de $87,51\% \pm 16,98$ con el clasificador BDLDA. A pesar de que en la práctica son buenos resultados, el alto valor de desviación

estándar indica que hay una alta dispersión de los porcentajes de precisión, por lo que los resultados no son tan confiables como se aparenta ya que, además, no se explicitan los valores de sensibilidad y especificidad. Además, se tiene una baja cantidad de muestras en la base de datos con una mayor relación para los grupos de control. En esta memoria se utilizarán bases de datos con muchas muestras para evitar este problema, y además se utilizará validación cruzada de Monte Carlo en lugar de *leave-one-out* que, como se verá más adelante, permitirá reducir la desviación estándar de los resultados de clasificación.

Por último, en el artículo *Machine-learning-based diagnosis of schizophrenia using combined sensor-level and source-level EEG features*[32] consiste en utilizar combinaciones de características a nivel de sensor (sensor-level, amplitudes y latencias de ERP) con características a nivel de fuente (source-level, filtrado de señales) puesto que utilizar ambas implicaría en un aumento en la precisión de los clasificadores para el problema de clasificación de esquizofrenia. La base de datos consistía en señales EEG de 64 canales de 34 pacientes con esquizofrenia y 34 voluntarios en el grupo de control. Los sujetos fueron sometidos al 'auditory oddball paradigm' (paradigma auditivo), similar a los test Double Flash y MMN, donde se plantea que la amplitud del ERP P300 es mayor en las muestras del grupo de control que en los pacientes con esquizofrenia, lo que también es cierto para las actividades a nivel de fuente (source-level). Los estímulos utilizados para el paradigma auditivo de los juegos de azar estaban compuestos por tonos objetivo con una frecuencia de tono de 1500 Hz y tonos estándar con una frecuencia de tono de 1000 Hz. La duración de cada estímulo se estableció en 100 ms, y los tiempos de subida y bajada se establecieron en 10 ms. Se presentaron cuatrocientos estímulos de tonos puros que consistían en un 15% de tonos objetivo y un 85% de tonos estándar en un orden aleatorio con un intervalo entre estímulos (ISI) de 1500 ms. Los participantes debían presionar un botón de respuesta cuando se presentaban los tonos de destino.

El conjunto de características de nivel de sensor se calculó obteniendo las amplitudes y latencias P300 de los 62 canales después de realizar procesamiento a las señales EEG, llegando a 124 características por muestra. Para extraer características de nivel de fuente, las señales EEG se segmentaron en intervalos temporales y se estimaron las distribuciones de la densidad de corriente cortical en cada punto de tiempo o época, mediante el uso de librerías especializadas de Matlab. Se extrajeron 314 fuentes de dipolos lo más uniformemente posible del modelo de superficie cortical original. Cada una de estas 314 señales de series de tiempo se promedió en el tiempo de 0 a 500 ms después del inicio del estímulo objetivo. En total, se utilizaron 314 valores promedios de densidad de corriente cortical como características candidatas a nivel de fuente. Los conjuntos por clasificar fueron los siguientes: solo sensor-level (124 características), solo source-level (314 características), conjunto combinado (438 características). Para seleccionar que características se iban a utilizar para la clasificación, se compararon los puntajes de Fisher de cada característica candidata resultando en un rango de 1 a 20 características, mientras que la precisión de la clasificación se realizó mediante *leave-one-out cross validation* (LOOCV) y el uso del clasificador Support Vector Machine, obteniendo los siguientes resultados:

Table 2

Classification accuracies (unit: %) for three different feature sets: sensor-level, source-level, and combined feature sets. The last column shows the ratio of sensor-level features and source-level features included in the selected combined feature set. Bold letters represent the maximum accuracy of each feature set.

Number of features	Accuracy			Sensor feature/ source feature
	Sensor level	Source level	Combined	
1	75.00	69.12	79.41	0/100
2	67.65	79.41	76.47	0/100
3	72.06	80.88	76.47	0/100
4	77.94	85.29	72.06	25.0/75.0
5	69.12	77.94	82.35	20.0/80.0
6	79.41	83.82	72.06	16.7/83.3
7	79.41	63.24	86.76	28.6/71.4
8	76.47	67.65	83.82	37.5/62.5
9	63.24	67.65	80.88	44.4/55.6
10	80.88	79.41	80.88	50.0/50.0
11	69.12	69.12	79.41	45.5/54.5
12	76.47	66.18	80.88	50.0/50.0
13	67.65	82.35	77.94	58.3/41.7
14	73.53	72.06	75.00	57.1/42.9
15	72.06	58.82	88.24	53.3/46.7
16	64.71	66.18	76.47	56.3/43.7
17	70.59	73.53	72.06	58.8/41.2
18	72.06	61.76	70.59	61.1/38.9
19	72.06	67.65	82.35	63.2/36.8
20	75.00	55.88	70.59	65.0/35.0
Average \pm s.d.	72.72 \pm 4.92	71.40 \pm 8.58	78.24 \pm 5.19	50.5/49.5

Figura 3.4: Resultados de clasificación para distintos conjuntos.

Se aprecia que la mayor precisión alcanzada es para el conjunto combinado con 15 características, donde hay una mayor cantidad de características obtenidas a nivel de sensor que de fuente. También es importante notar que la precisión promedio de los conjuntos combinados es mayor que la de los conjuntos por separado, y que la precisión máxima alcanzada por source-level es mayor que la máxima alcanzada por sensor-level. Las limitaciones que tiene este artículo es que la extracción de características a nivel fuente (series de tiempo) puede no ser la adecuada por lo que afecta los resultados del experimento en general, ya que existen otras metodologías de extracción de características como las planteadas en esta memoria. También es importante destacar que existen otras metodologías de selección de características además de los puntajes de Fisher, tales como usar el evaluador de Random Forest, métodos analíticos de entropía o bien usar programas como WEKA que se abordará en este trabajo. Otra limitación es el uso exclusivo de Support Vector Machine para clasificar ya que en otros trabajos se utilizan arboles de decisión como Random Forest que, por lo general, entrega mejores resultados.

En general, la bibliografía encontrada tiene relación con el problema que se plantea en este informe y se obtienen buenos resultados, pero al ser problemas de clasificación binarios (esquizofrenia vs. control) no representan completamente la problemática de clasificación de trastornos psicóticos, ya que en esta última se tiene una mayor variedad tanto de clases como de muestras y tareas realizadas por pacientes, lo que podría dificultar la implementación de estas metodologías y algoritmos en un problema de clasificación multiclase. Sin embargo, dado que los resultados son optimistas, la bibliografía revisada plantea buenas técnicas de extracción de características de señales EEG, donde ahora lo importante es determinar cuáles de estas son las de mayor relevancia y su relación con los canales EEG.

Capítulo 4

Desarrollo

4.1. Procesamiento de señales

Para realizar el procesamiento de señales, se crearon *scripts* de Matlab para cargar las muestras en su formato original `.bdf` y, mediante la función `pop_biosig()` de EEGLAB transformarlas a un formato de estructura que pueda ser leído por Matlab. Luego, se realizaron 5 metodologías distintas de procesamiento sobre las muestras del conjunto Resting State, resultando en 5 bases de datos distintas:

1. Filtrado pasabanda entre 0.5 y 60 Hz mediante filtro de fase cero `filtfilt()` sobre las señales, seguido de eliminación de artefactos mediante algoritmo ICA y *Adjust* y finalmente submuestreo de 2048 Hz a 256 Hz.
2. Submuestreo de la señal a 256 Hz, seguido de filtrado pasabanda entre 0.5 y 60 Hz mediante filtro FIR `pop_eegfiltnew()` y finalmente eliminación de artefactos por ICA y *Adjust*.
3. Primer método sin remoción de artefactos.
4. Segundo método sin remoción de artefactos.
5. Primer método con submuestreo a 128 Hz.

Este procesamiento se realizó para los 72 canales de todas las muestras de Resting State. Cabe destacar que el posicionamiento del submuestreo de la señal en las metodologías de procesamiento es de vital importancia, puesto que, si se hubiera submuestreado la señal después de hacer un filtrado pasabanda usando el filtro FIR, el orden de filtrado habría sido demasiado alto (aprox. 135000) y el tiempo de procesamiento para cada muestra por si sola habría demorado **días**, por la gran cantidad de datos al tener una frecuencia de 2048 Hz. Esto no es así para la metodología con filtro `filtfilt`, ya que el usuario debe escoger el orden del filtro, donde en este caso se eligió un valor igual a 2 puesto que no alteraba la forma de las señales como en filtros de mayor orden. Por lo demás, el algoritmo ICA se ejecutó usando su versión binaria compilada en lenguaje C, lo que permite al algoritmo optimizar el uso de memoria y tiempo de procesamiento. Las muestras se guardaron en formato de estructura de Matlab donde cada muestra es su propio archivo `.mat`.

4.2. Extracción de características

La extracción de características de las señales se realizó utilizando las funciones de *EntroPy* junto a las funciones complementarias de *PyEEG*. Cabe destacar que ambas librerías poseen funciones en común, tales como análisis de fluctuación de tendencia y método Petrosian, con la diferencia que las funciones de *EntroPy* utilizan el compilador de libre acceso para Python conocido como *Numba* que permite aumentar la velocidad de procesamiento de los algoritmos, por lo que tales funciones en *EntroPy* se prefirieron por sobre *PyEEG*. La metodología de extracción de características consistió básicamente en leer los archivos `.mat` a través de Python mediante la librería *scipy* para guardar todas las muestras como estructura de Python, donde cada muestra es representada por los 72 canales en forma de series de tiempo. Luego, se itera sobre todas las muestras del conjunto Resting State, y sobre cada canal se calculan las siguientes características:

1. Intensidad de potencia espectral y razón de intensidad relativa para 5 bandas de frecuencia representadas por `[0,5, 4, 7, 12, 30, 60]`, resultando en un total de 10 valores numéricos mediante la función `pyeeg.bin_power()`.
2. Dimensión fractal mediante metodologías Petrosian, Higuchi y Katz usando las funciones de EntroPy `petrosian()`, `higuchi_fd()` con retraso de 10, y `katz()`
3. Parámetros de Hjorth mediante `pyeeg.hjorth()`, retornando valores para movilidad y complejidad.
4. Los 3 tipos de entropías: espectral, SVD y de permutación mediante las funciones `pyeeg.spectral_entropy()` que utiliza los valores de RIR, `entropy.svd_entropy()` de orden 5 y retraso 1, y `entropy.perm_entropy()` de orden 5, respectivamente.
5. Información de Fisher usando `pyeeg.fisher_info` de orden 5 y retraso 1.
6. Análisis de fluctuación sin tendencia mediante `entropy.detrended_fluctuation()`.

Teniendo esto, cada canal de una muestra será representado por un arreglo de 20 características o valores el cual será concatenado a los valores obtenidos de los canales restantes, obteniendo de esta forma un vector de características con $20 \times 72 = 1440$ valores. Adicionalmente, se realizaron experimentos utilizando solamente las funciones de PyEEG, reduciendo el tamaño del vector de 1440 a $17 \times 72 = 1224$.

4.3. Clasificación de datos usando tarea Resting State

4.3.1. Etiquetado y separación de conjuntos

Teniendo los vectores de características de las muestras, están deben ser etiquetas con un valor numérico en función de la clase que cada muestra representa. Dado que se tienen 5 grupos de pacientes, se realizarán pruebas para las siguientes agrupaciones de clases:

1. **Control** (CNTF) y **Esquizofrenia** (FEP+EQZ). Dado que los sujetos que presentan síntomas de primer episodio psicótico y esquizofrenia son de avanzada edad, es lógico compararlos con los sujetos del grupo de control adulto. Además, se decidió agrupar los conjuntos FEP y EQZ puesto que EQZ tiene pocas muestras. Para Resting State se tendrán en total 64 muestras pertenecientes a estos conjuntos.

2. **Control** (CNTA) y **Psicosis atenuada** (APS). El síndrome de psicosis atenuada se asocia de mayor forma con pacientes más jóvenes, puesto que es un tipo de psicosis leve. En Resting State se tienen 35 muestras, lo que es menor a la agrupación anterior. También se estudiará el caso para CNTF vs. APS ya que el primero presenta mayor cantidad de muestras que CNTA, lo que afecta el rendimiento del clasificador.
3. **Control** (CNTA+CNTF) y **Psicosis** (APS+FEP+EQZ). Esta agrupación se utilizará para analizar el rendimiento de los clasificadores al comparar el grupo de pacientes sanos generalizado contra los pacientes con algún grado de psicosis. Se utilizarán todas las 99 muestras de la base de datos Resting State.
4. **Control** (CNTA+CNTF), **Psicosis atenuada** (APS) y **Esquizofrenia** (FEP+FEP). Este problema de 3 clases servirá para comparar los rendimientos al clasificar grupos de control , psicosis leve y psicosis grave.
5. CNTF, CNTA, APS, FEP y EQZ por separado, para estudiar el comportamiento de los clasificadores al tener un problema de mayor dimensionalidad (mayor cantidad de clases), que se conocen por ser problemas de difícil resolución.

Luego, para establecer los conjuntos de entrenamiento y prueba se utilizará la función de *sklearn* conocida como `train_test_split()`, la cual divide una base de datos en los conjuntos de entrenamiento y prueba según una proporción, en este caso 70/30, guardando la razón entre las clases y retornando ambos conjuntos con sus respectivas etiquetas de clase. Cabe destacar que cada vez que se ejecuta esta función se tienen diferentes combinaciones de muestras en los conjuntos de entrenamiento y prueba, lo que será útil para la validación de los resultados mediante

4.3.2. Clasificadores y ajuste de hiperparámetros

Los clasificadores a utilizar se encuentran en su totalidad disponibles en la librería *sklearn*. Sin embargo, algunos de estos clasificadores necesitan un ajuste de parámetros, también conocidos como hiperparámetros, los cuáles son fundamentales para obtener buenos resultados en el entrenamiento y clasificación de las muestras. Una forma de automatizar este proceso de ajuste es utilizando la función de *sklearn* conocida como `GridSearchCV()` la cual recibe un modelo de clasificación y una lista de parámetros para evaluar en el modelo, retornando el modelo con los parámetros óptimos. En el siguiente bloque de código se presentarán los clasificadores utilizados junto a sus parámetros óptimos encontrados por *GridSearchCV*, con la excepción del clasificador Support Vector Machine cuyos parámetros por defecto entregaron buenos resultados:

```

1 from sklearn.ensemble import RandomForestClassifier
2 clf1 = RandomForestClassifier(bootstrap=True,
3     class_weight=None, criterion='entropy', max_depth=None,
4     max_features=0.25, max_leaf_nodes=None,
5     min_impurity_decrease=0.0, min_impurity_split=None,
6     min_samples_leaf=5, min_samples_split=2,
7     min_weight_fraction_leaf=0.0, n_estimators=100,
8     n_jobs=None, oob_score=False, random_state=None,
```

```

9     verbose=0, warm_start=False)
10 from sklearn.neighbors import KNeighborsClassifier
11 clf2 = KNeighborsClassifier(n_neighbors=10, weights='uniform')
12 from sklearn.ensemble import GradientBoostingClassifier
13 clf3 = GradientBoostingClassifier(n_estimators=100,
14     subsample=0.25)
15 from sklearn.discriminant_analysis import
16     LinearDiscriminantAnalysis
17 clf4 = LinearDiscriminantAnalysis(solver='eigen', shrinkage=0.9)
18 from sklearn.neural_network import MLPClassifier
19 clf5 = MLPClassifier(activation='tanh', alpha=1e-10,
20     batch_size='auto', beta_1=0.9, beta_2=0.999,
21     early_stopping=False, epsilon=1e-08,
22     hidden_layer_sizes=(100, 2), learning_rate='constant',
23     learning_rate_init=0.001, max_iter=200, momentum=0.9,
24     n_iter_no_change=10, nesterovs_momentum=True, power_t=0.5,
25     random_state=None, shuffle=True, solver='adam', tol=0.0001,
26     validation_fraction=0.1, verbose=False, warm_start=False)
27 from sklearn.svm import SVC
28 clf6 = SVC() #default: kernel='rbf', C=1.0, gamma='scale'

```

El algoritmo de clasificación guarda los mejores y peores rendimientos obtenidos para los 6 clasificadores en 50 iteraciones distintas (o combinaciones de conjuntos) para la validación cruzada de Monte Carlo. En caso de que el problema sea de clasificación binaria, también se obtendrá la sensibilidad y especificidad de los clasificadores, que se definen como la proporción de casos con psicosis correctamente identificados y la proporción de sanos correctamente identificados, respectivamente.

4.3.3. Resultados preliminares de clasificación binaria

Comparación de bases de datos

A continuación, se presentarán los resultados de clasificación de las 5 bases de datos distintas, para el problema de clasificación Control vs. Esquizofrenia, puesto que los datos se diferencian de mejor manera entre sí, usando 1224 características y validación cruzada de Monte Carlo con 50 iteraciones, destacando los mejores resultados porcentuales para los valores de precisión, sensibilidad y especificidad:

- Metodología de procesamiento 1: filtfilt+ICA

Clasificadores	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
Random Forest	72.10	9.28	60.47	12.62	81.62	10.05
K-Nearest Neighbors	73.90	7.09	51.56	12.15	92.17	6.81
Gradient Boosting	73.5	8.26	62.02	12.99	82.89	11.31
Linear Discriminant Analysis	76.9	8.65	68.47	10.97	83.80	9.85
Multi-Layer Perceptron	75.8	10.26	73.14	15.40	77.98	15.44
Support Vector Machine	75.8	8.62	59.80	11.96	88.90	9.68

Tabla 4.1: Validación cruzada de Monte Carlo, metodología 1 con 1224 características.

Las siguientes corresponden a la mejor y peor matriz de confusión conseguida de forma combinada por los 6 clasificadores anteriores:




Figura 4.1: Matrices de confusión metodología 1, 1224 características.

Para esta metodología se aprecia la obtención de buenos resultados donde la precisión promedio para los 6 clasificadores es mayor a 72 % pero con desviaciones estándar

relativamente altas, lo que implica que los resultados de precisión tienen una alta dispersión. El clasificador con mayor consistencia (i.e. de menor dispersión) corresponde a K-Nearest Neighbors, el cual tiene el más alto porcentaje de especificidad y el más bajo porcentaje de sensibilidad, lo que implica que clasifica de mejor manera las muestras del grupo de control, pero el más deficiente al clasificar esquizofrenia. Por otro lado, el menos consistente resultó ser Multi-Layer Perceptron el cual consiguió la mejor y peor precisión para esta metodología en 50 iteraciones, lo que se refleja en lo obtenido por las matrices de confusión. El clasificador con el mejor rendimiento en general es LDA, puesto que alcanzó la mejor precisión promedio con consistencia intermedia.

- **Metodología de procesamiento 2: eegfilt+ICA**

Clasificadores	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
Random Forest	71.50	8.62	56.91	11.49	83.44	9.75
K-Nearest Neighbors	64.10	8.76	35.98	16.28	87.08	8.75
Gradient Boosting	68.60	8.78	53.13	11.84	81.26	11.27
Linear Discriminant Analysis	72.40	6.65	59.58	10.38	82.89	7.64
Multi-Layer Perceptron	70.20	8.30	66.25	13.14	73.43	16.75
Support Vector Machine	70.30	8.57	51.35	12.38	85.80	8.95

Tabla 4.2: Validación cruzada de Monte Carlo, metodología 2 con 1224 características.




Figura 4.2: Matrices de confusión metodología 2, 1224 características.

Comparando esta metodología con la anterior se obtienen resultados más deficientes, lo que implicaría que el método de filtrado usando filtro fase cero de orden 2 de Matlab es más eficiente y brinda mejores resultados que utilizar el filtro FIR de EEGLAB. Al igual que la primera metodología, en este caso el clasificador de mayor precisión y consistencia en general resulta ser LDA, mientras que el peor clasificador en general es

KNN. Sin embargo, esto no se refleja en el mejor y peor resultado obtenido durante la validación cruzada, donde la mejor precisión fue conseguida por Multi-Layer Perceptron mientras que la peor fue de Gradient Boosting.

- **Metodología de procesamiento 3: filfilt**

Clasificadores	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
Random Forest	71.90	8.12	59.81	10.87	81.80	8.73
K-Nearest Neighbors	66.40	6.33	39.09	12.23	88.72	7.84
Gradient Boosting	68.50	7.43	55.79	11.25	78.89	9.18
Linear Discriminant Analysis	70.20	8.60	60.91	12.44	77.80	8.37
Multi-Layer Perceptron	66.70	11.30	65.80	16.01	67.43	18.72
Support Vector Machine	70.50	8.56	53.34	11.36	84.53	9.15

Tabla 4.3: Validación cruzada de Monte Carlo, metodología 3 con 1224 características.

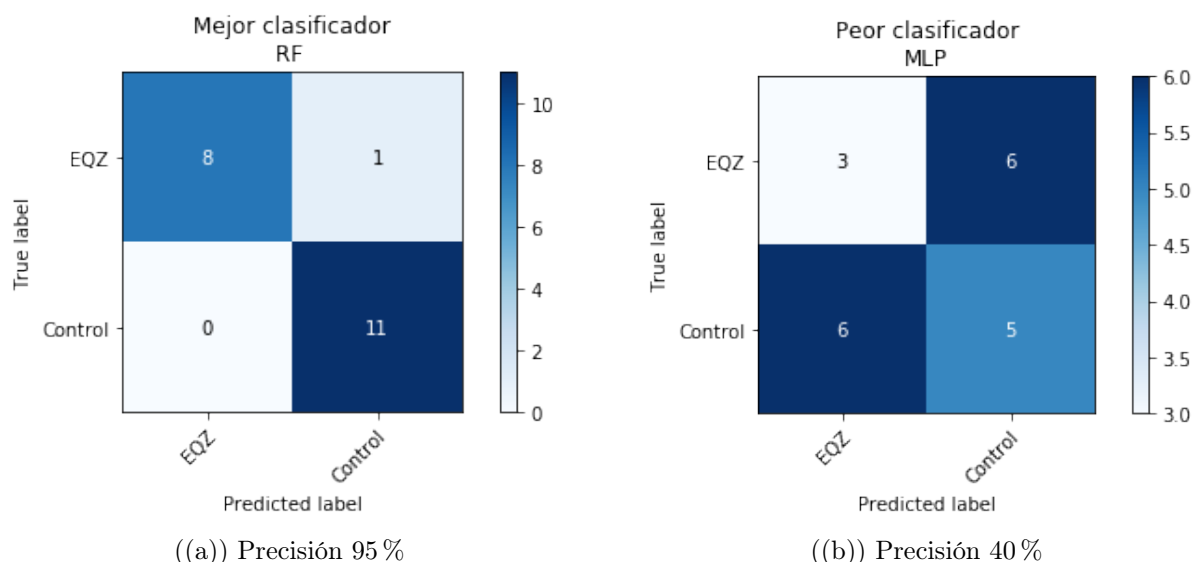


Figura 4.3: Matrices de confusión metodología 3, 1224 características.

En el caso de procesamiento usando solamente filtrado fase cero y submuestreo, los resultados obtenidos son similares a la metodología anterior pero inferiores a la primera. Esto es conveniente puesto que al no requerir de eliminación de artefactos por medio de ICA y Adjust se reduce drásticamente el tiempo de procesamiento de las señales comparado con la metodología anterior. Aun así, no se alcanzan los porcentajes máximos alcanzados en la primera metodología, por lo que se deduce que es importante eliminar artefactos de las señales, pero no es óptimo añadir un filtro pasabanda usando la función de EEGLAB debido a que este último filtro se aplicó a una señal ya submuestreada, por lo que se perdió información. Por lo demás el clasificador más consistente para este caso es KNN, pero también es el que tiene peor sensibilidad. El mejor clasificador para esta metodología es Random Forest, puesto que alcanzó la máxima precisión junto a la mayor precisión promedio y con consistencia media.

- Metodología de procesamiento 4: eegfilt

Clasificadores	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
Random Forest	73.60	8.60	61.36	9.50	83.62	10.91
K-Nearest Neighbors	67.60	8.20	39.54	13.56	90.54	6.55
Gradient Boosting	73.60	8.95	60.02	13.16	84.71	9.36
Linear Discriminant Analysis	70.50	8.73	61.35	10.96	77.98	9.98
Multi-Layer Perceptron	68.00	9.11	64.69	14.69	70.71	16.69
Support Vector Machine	71.10	9.40	52.23	13.95	86.53	8.96

Tabla 4.4: Validación cruzada de Monte Carlo, metodología 4 con 1224 características.




Figura 4.4: Matrices de confusión metodología 4, 1224 características.

Utilizando solamente el filtro de EEGLAB se obtienen mejores resultados que al utilizar solo el filtro fase cero de Matlab, pero el tiempo de procesamiento de señales aumenta considerablemente. Cabe destacar que además de aumentar la precisión promedio de los clasificadores se normalizan sus desviaciones estándar a valores levemente más bajos y altos según sea el caso, lo que se ve reflejado en las matrices de confusión puesto que es la menor diferencia porcentual (45%) entre las matrices obtenidas por las metodologías anteriores. Es destacable que hasta ahora esta metodología ha sido la única que se acerca a resultados similares a la primera metodología, pero siguen siendo marginalmente inferiores.

- Metodología de procesamiento 5: filtfilt+ICA 128 Hz

Clasificadores	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
Random Forest	71.70	6.97	62.25	10.43	79.43	8.88
K-Nearest Neighbors	72.90	8.31	51.12	14.60	90.72	9.01
Gradient Boosting	74.20	9.08	64.02	13.45	82.53	10.43
Linear Discriminant Analysis	75.00	7.68	66.48	9.55	81.98	10.05
Multi-Layer Perceptron	75.80	7.57	72.69	15.10	78.34	9.44
Support Vector Machine	75.40	6.77	63.14	9.02	85.44	8.73

Tabla 4.5: Validación cruzada de Monte Carlo, metodología 5 con 1224 características.

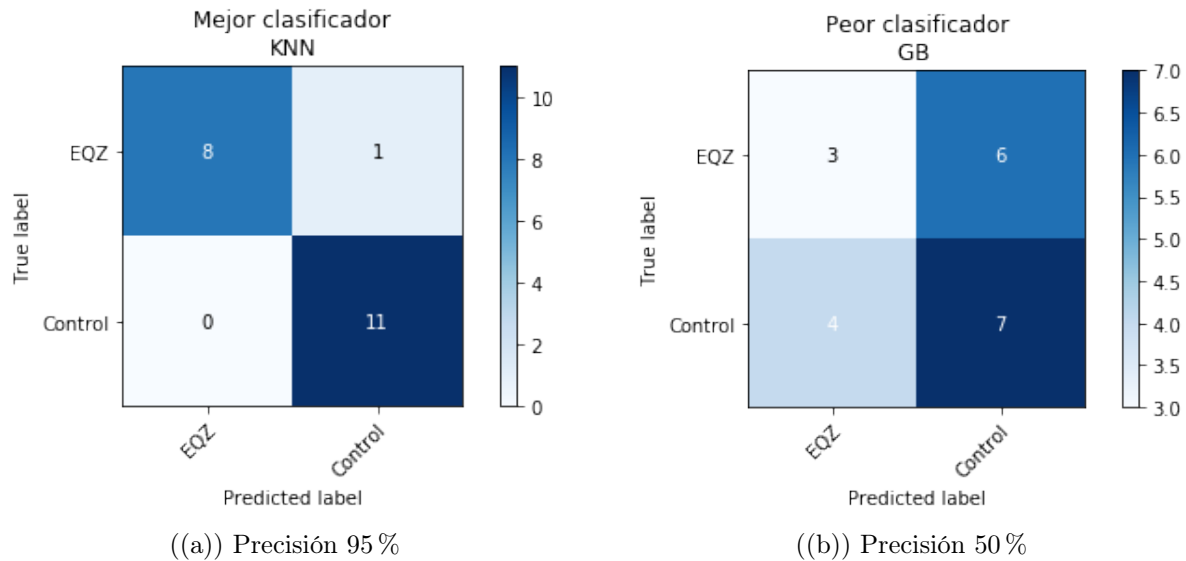


Figura 4.5: Matrices de confusión metodología 5, 1224 características.

Finalmente se obtienen los resultados para la última metodología, los cuáles son bastante similares a la primera para los clasificadores LDA, MLP y SVM. La ventaja que aquí se observa es la baja en la desviación estándar de los porcentajes, lo que permite un proceso de clasificación más consistente. Es de notar que esta metodología obtuvo la más alta peor precisión de los 5 métodos de procesamiento correspondiente a un 50%, lo que es importante para una señal con menor cantidad de información o datos que la metodología 1.

Teniendo estos resultados, se deduce que las bases de datos que mejor resuelven el problema de clasificación binario son las obtenidas mediante procesamiento con filtro de Matlab y eliminación de artefactos por ICA y Adjust, tanto para 256 Hz como para 128 Hz. Por lo tanto, para las próximas pruebas se utilizarán solamente estos conjuntos.

Comparación algoritmos de extracción de caract. y frecuencia de muestreo

A continuación, se presentan los resultados de clasificación para las bases de datos utilizando la metodología de extracción de 1440 características por muestra, donde en lugar de utilizar todas las funciones integradas en PyEEG, se reemplazaron las funciones correspondientes por las implementadas en Entropy junto con la adición de las dimensiones fractales de Higuchi y Katz y entropía de permutación. Las funciones de Higuchi y exponente de Hurst de PyEEG no fueron implementadas puesto que sus tiempos de procesamiento son excesivamente largos. Pese a que las nuevas base de datos contienen 216 características adicionales, el tiempo que demoran en extraerse es menor que al utilizar la otra metodología, ya que como se mencionó anteriormente Entropy usa la librería *Numba*.

- Muestras a 128 Hz con 1440 características

Clasificadores	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
Random Forest	73.80	10.42	61.80	12.62	83.62	11.65
K-Nearest Neighbors	73.20	7.40	43.99	14.42	97.09	5.29
Gradient Boosting	75.40	8.99	65.36	12.50	83.62	11.07
Linear Discriminant Analysis	76.10	8.44	65.58	13.20	84.71	8.43
Multi-Layer Perceptron	76.90	8.94	74.47	12.61	78.89	10.83
Support Vector Machine	78.00	7.28	65.14	11.55	88.53	8.69

Tabla 4.6: Validación cruzada, conjunto 128 Hz con 1440 características.




Figura 4.6: Matrices de confusión conjunto 128 Hz, 1440 características.

En este caso se aprecia un aumento general en los porcentajes promedio obtenidos por los clasificadores, superando incluso los resultados de la primera metodología con 1224 características. Por otro lado, pese a que SVM alcanzó la mejor precisión promedio con

alta consistencia, el valor de sensibilidad promedio es bajo comparado con los resultados de MLP, donde este último alcanzó el valor más alto obtenido hasta ahora pero también una relativamente baja especificidad. Por último, dado además por el resultado de las matrices de confusión, el clasificador MLP es el que mejor clasifica correctamente las muestras con etiquetadas como esquizofrenia en todas las metodologías.

- **Muestras a 256 Hz con 1440 características:**

Clasificadores	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
Random Forest	73.70	6.62	62.92	9.59	82.53	7.47
K-Nearest Neighbors	74.10	7.85	52.23	13.40	91.99	7.64
Gradient Boosting	73.20	7.60	61.13	11.83	83.07	9.28
Linear Discriminant Analysis	78.70	8.41	70.69	11.49	85.26	8.52
Multi-Layer Perceptron	77.50	9.55	74.91	12.73	79.62	10.22
Support Vector Machine	76.70	6.97	61.58	9.75	89.08	7.72

Tabla 4.7: Validación cruzada, conjunto 256 Hz con 1440 características.

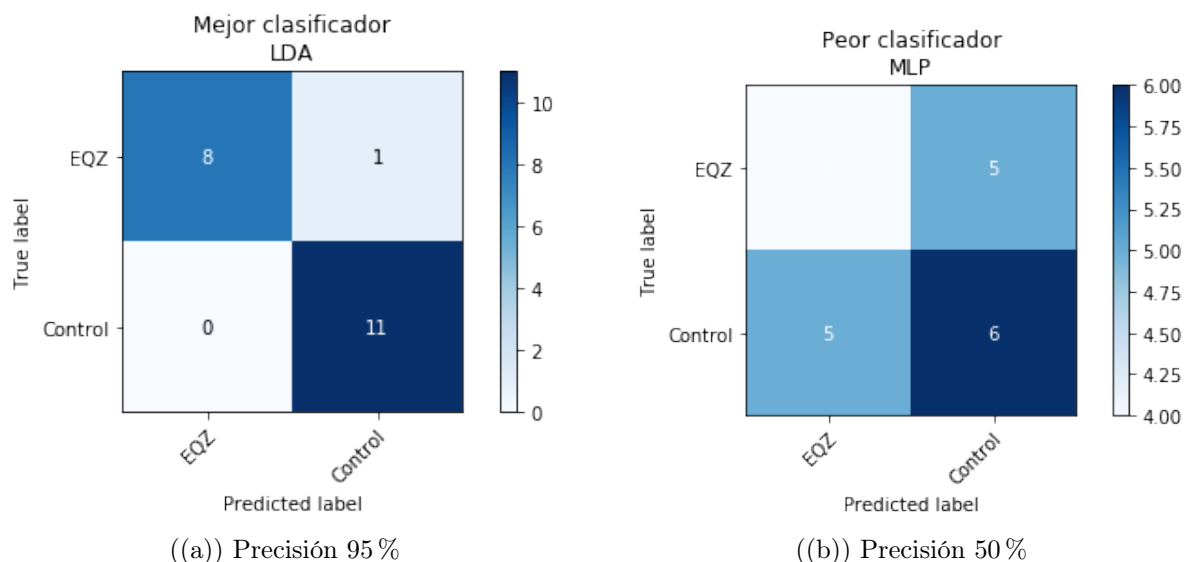


Figura 4.7: Matrices de confusión conjunto 256 Hz, 1440 características.

Para el caso de la base de datos muestreada a 256 Hz, se obtienen resultados similares a la base de datos de 128 Hz, siendo mejores una vez más que su símil de 1224 características. La diferencia fundamental con su par de 128 Hz es que en este caso el clasificador LDA supera a MLP tanto en precisión como en especificidad, pero no en sensibilidad. Sin embargo, LDA tiene mayor consistencia que MLP y su promedio de sensibilidad es tan solo $\sim 4\%$ inferior a MLP lo que se demuestra en las matrices de confusión obtenidas, donde el mayor porcentaje de precisión es para LDA y el menor para MLP. Cabe destacar que para ambas bases de datos el clasificador SVM ha tenido un buen desempeño con una baja desviación estándar en todas las metodologías estudiadas.

Separación de señal en ojos abiertos y cerrados

Teniendo estos datos, ahora se procederá a obtener resultados de clasificación considerando señales individuales tanto para ojos abiertos como para ojos cerrados, lo que implica dividir las muestras en 2 partes iguales y duplicar la cantidad de características utilizando la metodología de extracción presentada en esta subsección:

- **Muestras a 128 Hz con 2880 características:**

Clasificadores	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RandomForest	70.60	8.81	56.25	10.30	82.35	11.57
K-nearest Neighbors	71.40	7.94	44.43	12.40	93.45	7.29
GradientBoosting	70.90	8.81	56.46	13.69	82.71	10.64
Linear Discriminant Analysis	71.50	7.23	63.13	11.22	78.34	8.71
Multi-Layer Perceptron	72.50	9.76	66.47	16.41	77.43	10.49
Support Vector Machine	77.80	6.65	61.14	10.73	91.45	6.91

Tabla 4.8: Validación cruzada, conjunto 128 Hz con 2880 características




Figura 4.8: Matrices de confusión conjunto 128 Hz, 2880 características.

Al dividir las señales en 2 series de tiempo y aumentar la cantidad de características por muestra se obtienen resultados más deficientes que al utilizar la mitad de las características. Esto puede deberse a un sobreajuste en la clasificación de los datos ya que el sistema al tener más características puede volverse más específico. También es posible que la señal de ojos abierto no sea tan distinta a la de ojos cerrados, provocando que se calculen características redundantes. Es importante notar que el clasificador SVM obtuvo un muy buen rendimiento y consistencia con respecto a los otros clasificadores, ya que se acerca los valores máximos de precisión promedio obtenidos hasta el momento.

- Muestras a 256 Hz con 2880 características:

Clasificadores	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RandomForest	72.30	8.32	60.25	9.72	82.16	10.61
K-nearest Neighbors	72.20	7.01	47.55	12.80	92.36	7.13
GradientBoosting	70.20	7.55	57.35	11.43	80.71	9.57
Linear Discriminant Analysis	75.20	7.61	66.69	9.94	82.16	8.91
Multi-Layer Perceptron	72.90	11.09	71.14	17.78	74.35	18.42
Support Vector Machine	75.60	7.59	58.69	9.71	89.44	8.61

Tabla 4.9: Validación cruzada, conjunto 256 Hz con 2880 características

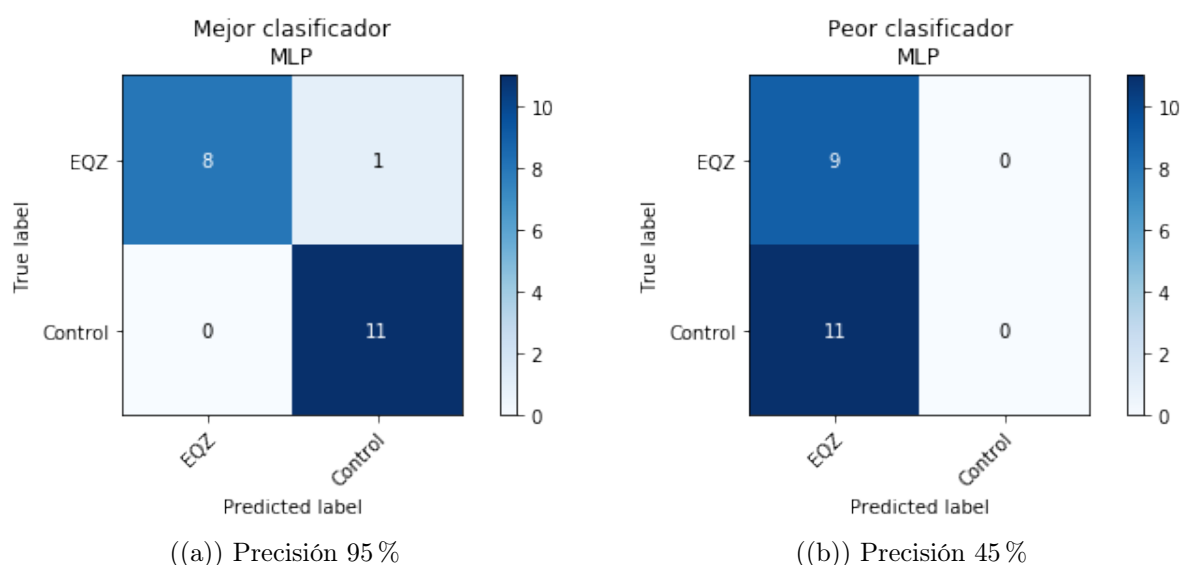


Figura 4.9: Matrices de confusión conjunto 256 Hz, 2880 características.

Tal como el caso anterior se aprecia una disminución general en la precisión de los clasificadores donde los únicos clasificadores que se acercan a los buenos porcentajes son LDA y SVM, notando como caso especial el clasificador MLP el cual tiene la mejor sensibilidad promedio, pero la mayor desviación estándar del sistema, mientras que su especificidad promedio es la más baja pero también su desviación estándar es la más alta. Este comportamiento de inconsistencia se manifiesta en las matrices de confusión puesto que tanto la precisión máxima y mínima fueron conseguidas por MLP.

4.3.4. Selección de canales

Como se mencionó en la sección de metodología, se utilizará el algoritmo de entropía aproximada para seleccionar los canales que aportan más información. Para ello, se calcula la ApEn de orden 2 de los 72 canales por separado para todas las muestras de la base de datos y se ordenaran los canales de mayor a menor ApEn para cada muestra, donde el canal que tenga mayor ApEn es el que aporta mayor cantidad de información. Luego, teniendo todas las muestras con sus canales más importantes sorteados, mediante una función se elegirán los canales que se encuentren dentro de las N posiciones más importantes por medio de un sistema de votación, donde si un cierto canal es el que más se repite dentro de esas N posiciones, el canal se añade a una lista con los canales más importantes. Luego se repite el procedimiento para los canales siguientes, completando una lista de N canales y retornando esta lista, pero ordenada según el valor numérico asignado a cada canal. Los canales obtenidos de esta lista serán utilizados para filtrar la cantidad de características en las bases de datos de 128 Hz y 256 Hz las cuáles serán filtradas a 54, 36, 18 y 6 canales que corresponden a 1080, 720, 360 y 120 características, respectivamente, considerando la exclusión de los 8 últimos canales que corresponden a señales de electrooculograma junto con nuevas mediciones considerando todos los canales de las señales (72 y 64 según corresponda). Para simplificar el análisis de resultados se estudiarán solo los clasificadores LDA, MLP y SVM sin considerar las matrices de confusión para el mejor y peor resultado. La siguiente tabla muestra las precisiones promedio conseguidas para 50 iteraciones, destacando los porcentajes mayores o iguales a 75 %:

Clasificador	Precisión 128 Hz [%]				Precisión 256 Hz [%]			
	Con señales EOG		Sin señales EOG		Con señales EOG		Sin señales EOG	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
LDA, s/s	75.70	7.87	75.80	8.68	79.50	6.42	77.20	8.20
MLP, s/s	76.30	9.94	75.60	10.89	77.90	7.82	76.10	9.02
SVM, s/s	77.60	7.89	77.30	8.20	76.80	7.40	74.60	6.84
LDA, 54 canales	74.70	7.64	77.00	7.75	77.30	7.01	74.50	9.55
MLP, 54 canales	74.90	8.57	76.00	11.75	75.80	9.40	72.40	10.59
SVM, 54 canales	76.80	7.05	78.10	6.92	75.10	7.45	73.90	7.09
LDA, 36 canales	74.10	7.79	75.60	8.28	73.80	8.40	75.20	7.93
MLP, 36 canales	72.80	9.12	74.70	8.33	73.70	8.53	74.10	8.58
SVM, 36 canales	75.00	7.42	77.70	7.89	73.70	7.93	75.70	7.87
LDA, 18 canales	74.40	8.81	73.40	8.33	76.20	8.28	72.70	8.26
MLP, 18 canales	71.00	8.89	71.80	9.68	73.70	8.23	71.30	10.14
SVM, 18 canales	75.90	7.26	76.30	7.60	78.30	7.91	75.10	7.65
LDA, 6 canales	67.10	7.88	74.30	8.72	73.00	10.44	75.10	7.52
MLP, 6 canales	61.30	9.94	70.40	8.99	67.30	10.40	70.30	10.36
SVM, 6 canales	69.00	9.49	71.60	8.03	71.10	8.90	71.40	6.00

Tabla 4.10: Precisión validación cruzada, conjuntos 128 y 256 Hz con selección de canales.

De la tabla anterior se aprecia que, al disminuir la cantidad de canales, y por ende de características, generalmente disminuye la precisión promedio de los clasificadores tanto para la base de datos de 128 Hz como para 256 Hz. Sin embargo, existen casos donde la precisión aumenta, como por ejemplo el clasificador SVM para 18 canales donde su precisión promedio aumentó con respecto al caso para 36 canales. Por otro lado, para las muestras de 128 Hz

se observa un incremento en la precisión al no considerar los 8 canales correspondientes a electrooculograma, mientras que para las muestras de 256 Hz ocurre lo contrario, con la excepción de algunos casos. También es de notar que utilizando apenas 6 canales no se obtienen malos resultados, siendo la peor precisión promedio de 61 % con desviación estándar de 9.94, y el mejor resultado de 75.1 % con desviación estándar 7.52. Es importante destacar que ante igualdad de condiciones para este análisis se consiguió una precisión promedio más alta que la conseguida en la tabla 4.7, de 79.5 % con 6.42 de desviación estándar contra 78.70 % y 8.41 de desviación estándar, lo que demuestra la variabilidad de la base de datos. Por último, los mejores resultados para el conjunto de 128 Hz son para 54 canales excluyendo EOG, mientras que para las muestras de 256 Hz los mejores resultados son para 72 canales. A continuación, se presentan los resultados de sensibilidad, destacando los mayores a 70 %:

Clasificador	Sensibilidad 128 Hz [%]				Sensibilidad 256 Hz [%]			
	Con señales EOG		Sin señales EOG		Con señales EOG		Sin señales EOG	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
LDA, s/s	66.47	10.55	67.14	11.54	71.14	8.31	68.92	10.18
MLP, s/s	72.24	16.52	72.91	17.38	74.69	14.24	72.25	12.42
SVM, s/s	63.36	11.39	66.03	10.75	62.25	9.69	60.92	8.68
LDA, 54 canales	65.81	9.64	70.47	11.46	69.58	9.38	66.69	12.96
MLP, 54 canales	70.69	15.03	77.58	16.09	74.02	16.41	68.69	19.21
SVM, 54 canales	64.02	12.09	64.91	11.42	60.47	10.47	58.69	11.57
LDA, 36 canales	67.58	10.62	68.03	9.84	66.47	11.65	65.36	11.90
MLP, 36 canales	70.47	11.88	71.14	14.74	70.25	14.98	71.80	10.71
SVM, 36 canales	59.58	9.89	64.25	12.24	61.58	10.24	62.47	11.53
LDA, 18 canales	66.25	10.88	68.69	11.26	69.81	11.33	63.36	10.25
MLP, 18 canales	64.25	18.77	70.69	17.32	67.36	18.38	68.69	11.69
SVM, 18 canales	62.92	9.59	64.48	10.18	67.36	9.00	61.14	9.50
LDA, 6 canales	60.91	10.96	69.58	11.51	67.80	12.03	69.14	9.75
MLP, 6 canales	55.79	15.34	66.69	13.71	66.91	15.64	66.69	16.63
SVM, 6 canales	49.11	12.81	55.35	13.63	52.46	12.00	51.34	10.43

Tabla 4.11: Sensibilidad validación cruzada, conjuntos 128 y 256 Hz con selección de canales.

De los datos comparativos de sensibilidad se aprecian porcentajes relativamente inconsistentes comparado con los resultados de precisión obtenidos anteriormente, ya que en ciertos casos al disminuir la cantidad de canales aumenta la sensibilidad promedio mientras que en otros casos disminuye. Se aprecia además que el clasificador MLP es que tiene los mejores porcentajes de sensibilidad promedio comparado con los otros dos clasificadores, lo que implica que MLP es el que clasifica de mejor manera las muestras etiquetadas como esquizofrenia, mientras que SVM es el que obtienen los porcentajes más bajos de clasificación. Comparando la utilización de los canales EOG, tal como la tabla comparativa de precisión para las muestras de 128 Hz se aprecia un aumento en los porcentajes al no incluir señales de electrooculograma, mientras que para el conjunto de 256 Hz en algunos casos disminuye mientras que en otros aumenta. Por último, el clasificador MLP para 128 Hz con 54 canales sin EOG fue el que consiguió la sensibilidad promedio más alta con 77.58 % pero con una alta desviación estándar de 16.09, mientras que la peor sensibilidad es para el clasificador SVM para 128 Hz con 6 canales incluyendo EOG con apenas 49.11 % y una desviación estándar de 12.81 %. Por último, se presenta la tabla con los resultados de especificidad:

Clasificador	Especificidad 128 Hz [%]				Especificidad 256 Hz [%]			
	Con señales EOG		Sin señales EOG		Con señales EOG		Sin señales EOG	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
LDA, s/s	83.26	8.98	82.89	10.07	86.35	8.39	83.98	9.38
MLP, s/s	79.62	11.44	77.80	15.56	80.53	10.30	79.25	10.77
SVM, s/s	89.26	9.04	86.53	10.49	88.72	9.73	85.80	8.37
LDA, 54 canales	81.98	9.54	82.35	8.62	83.62	8.92	80.89	9.15
MLP, 54 canales	78.34	10.60	74.71	21.69	77.25	14.69	75.43	16.79
SVM, 54 canales	87.26	7.50	88.90	8.59	87.08	8.93	86.35	8.19
LDA, 36 canales	79.43	8.88	81.80	9.46	79.80	8.97	83.26	7.13
MLP, 36 canales	74.70	14.58	77.62	10.16	76.52	10.15	75.98	12.17
SVM, 36 canales	87.62	9.41	88.72	9.38	83.62	8.73	86.53	7.98
LDA, 18 canales	81.07	9.60	77.25	9.84	81.44	9.27	80.34	8.80
MLP, 18 canales	76.52	16.18	72.70	15.96	78.89	9.88	73.44	17.70
SVM, 18 canales	86.53	8.19	85.99	9.32	87.26	8.73	86.53	7.98
LDA, 6 canales	72.16	8.99	78.16	9.80	77.25	12.24	79.98	8.92
MLP, 6 canales	65.80	13.66	73.43	12.19	67.61	15.34	73.25	19.28
SVM, 6 canales	85.26	11.05	84.89	10.86	86.35	10.34	87.81	7.85

Tabla 4.12: Especificidad validación cruzada, conjuntos 128 y 256 Hz con selección de canales

Tal como los datos de especificidad obtenidos en los otros experimentos, en este caso se presentan porcentajes alto de especificidad promedio los cuáles tienden a no variar demasiado al disminuir la cantidad de canales en los vectores de características, manteniendo sus valores máximos (SVM) sobre 85%. Sin embargo, para el conjunto de 128 Hz estos porcentajes por lo general disminuyen al no incluir los 8 canales de EOG, con excepciones en los resultados para 36 y 6 canales, lo que se repite para el conjunto de 256 Hz. Es importante notar que el clasificador SVM es el que mejor clasifica las muestras del grupo de control, siendo MVP el de peor rendimiento y por lo demás de peor consistencia al tener valores altos de desviación estándar. Por último, tomando los datos de las tablas de sensibilidad y especificidad se concluye que clasificador MVP es el mejor clasificando muestras de esquizofrenia, pero el peor clasificando muestras del grupo de control. Por el contrario, SVM es el que mejor clasifica muestras de control, pero el peor clasificando esquizofrenia, mientras que LDA posee un balance entre los dos casos.

Por completitud, del archivo de etiquetado de los canales se pueden conocer las denominaciones o etiquetas de los electrodos del casco utilizado para extraer las señales:

```

1 Etiquetas: ['Fp1', 'AF7', 'AF3', 'F1', 'F3', 'F5', 'F7', 'FT7'
2 , 'FC5', 'FC3', 'FC1', 'C1', 'C3', 'C5', 'T7', 'TP7', 'CP5'
3 , 'CP3', 'CP1', 'P1', 'P3', 'P5', 'P7', 'P9', 'P07', 'P03'
4 , 'O1', 'Iz', 'Oz', 'P0z', 'Pz', 'CPz', 'Fpz', 'Fp2', 'AF8'
5 , 'AF4', 'AFz', 'Fz', 'F2', 'F4', 'F6', 'F8', 'FT8', 'FC6'
6 , 'FC4', 'FC2', 'FCz', 'Cz', 'C2', 'C4', 'C6', 'T8', 'TP8'
7 , 'CP6', 'CP4', 'CP2', 'P2', 'P4', 'P6', 'P8', 'P10', 'P08'
8 , 'P04', 'O2', 'EXG1', 'EXG2', 'EXG3', 'EXG4', 'EXG5', 'EXG6',
   'EXG7', 'EXG8']

```

El algoritmo de selección de canales mediante ApEn obtuvo los siguientes resultados para los 4 experimentos, incluyendo los canales de EOG:

-
- 1 Mejores 6 canales: ['P1', 'Pz', 'F8', 'P2', 'EXG5', 'EXG6']
 - 2 Mejores 18 canales: ['AF7', 'F7', 'P1', 'Pz', 'CPz', 'Fpz', 'Fp2', 'AF8', 'F8', 'FT8', 'CP4', 'CP2', 'P04', 'EXG3', 'EXG4', 'EXG5', 'EXG6', 'EXG7']
 - 3 Mejores 36 canales: ['Fp1', 'AF7', 'F7', 'FT7', 'FC5', 'C1', 'C3', 'CP5', 'CP1', 'P1', 'Pz', 'CPz', 'Fpz', 'Fp2', 'AF8', 'AF4', 'AFz', 'Fz', 'F6', 'F8', 'FT8', 'FCz', 'Cz', 'C2', 'CP4', 'CP2', 'P2', 'P4', 'P6', 'P04', 'EXG2', 'EXG3', 'EXG4', 'EXG5', 'EXG6', 'EXG7']
 - 4 Mejores 54 canales: ['AF7', 'AF3', 'F1', 'F3', 'F5', 'F7', 'FT7', 'FC5', 'FC3', 'FC1', 'C1', 'C3', 'C5', 'CP5', 'CP3', 'CP1', 'P1', 'P3', 'P5', 'P7', 'Oz', 'Pz', 'CPz', 'Fpz', 'Fp2', 'AF8', 'AF4', 'AFz', 'Fz', 'F2', 'F4', 'F6', 'F8', 'FT8', 'FC6', 'FC4', 'FC2', 'FCz', 'Cz', 'C2', 'C4', 'C6', 'CP4', 'CP2', 'P2', 'P4', 'P6', 'P04', 'EXG2', 'EXG3', 'EXG4', 'EXG5', 'EXG6', 'EXG7']
-

Por otro lado, sin considerar las señales EXG del electrooculograma se obtuvo lo siguiente:

-
- 1 6 canales, sin EOG: ['AF7', 'P1', 'Pz', 'F8', 'P2', 'P04']
 - 2 18 canales, sin EOG: ['AF7', 'F7', 'P1', 'P0z', 'Pz', 'CPz', 'Fpz', 'Fp2', 'AF8', 'F6', 'F8', 'Cz', 'CP4', 'CP2', 'P2', 'P4', 'P6', 'P04']
 - 3 36 canales, sin EOG: ['Fp1', 'AF7', 'AF3', 'F5', 'F7', 'FT7', 'FC5', 'C1', 'C3', 'C5', 'CP5', 'CP3', 'CP1', 'P1', 'P3', 'P0z', 'Pz', 'CPz', 'Fpz', 'Fp2', 'AF8', 'AF4', 'AFz', 'Fz', 'F2', 'F4', 'F6', 'F8', 'FT8', 'Cz', 'C2', 'CP4', 'CP2', 'P2', 'P6', 'P04']
 - 4 54 canales, sin EOG: ['Fp1', 'AF7', 'AF3', 'F1', 'F3', 'F5', 'F7', 'FT7', 'FC5', 'FC3', 'FC1', 'C1', 'C3', 'C5', 'TP7', 'CP5', 'CP3', 'CP1', 'P1', 'P3', 'P5', 'P7', 'P9', 'Oz', 'Pz', 'CPz', 'Fpz', 'Fp2', 'AF8', 'AF4', 'AFz', 'Fz', 'F2', 'F4', 'F6', 'F8', 'FT8', 'FC6', 'FC4', 'FC2', 'FCz', 'Cz', 'C2', 'C4', 'C6', 'TP8', 'CP6', 'CP4', 'CP2', 'P4', 'P6', 'P8', 'P04', 'O2']
-

De estos canales, se aprecia que al elegir 6 se escogen mayoritariamente los electrodos P, que tienen relación con la percepción de estímulos como se verá en la sección 4.8. Para selecciones más altas, como 54 canales, se ve una tendencia por seleccionar los electrodos F, asociados al lóbulo frontal y a movimientos musculares.

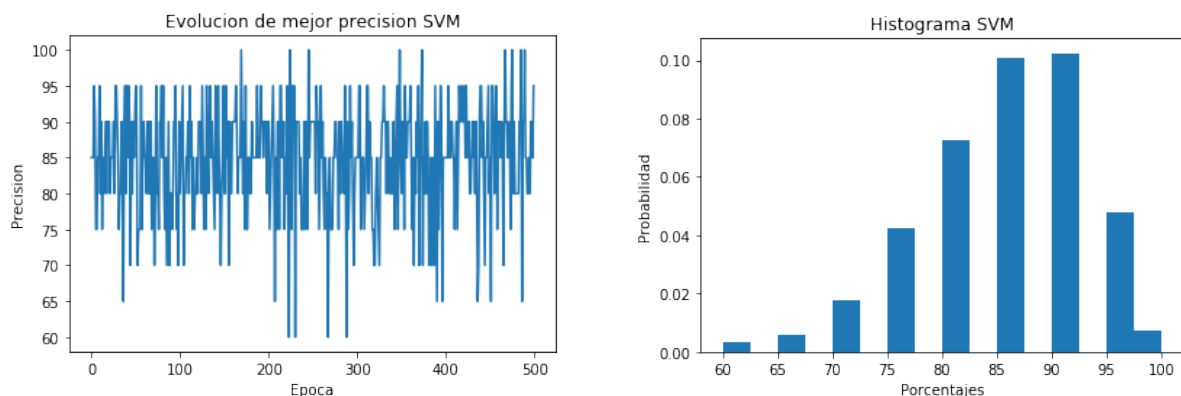
4.3.5. Clasificación de EQZ con selección de características

Usando la base de datos de 256 Hz con 1440 características, se procede a seleccionar las características más relevantes mediante las herramientas especializadas del software WEKA. El método de selección denominado **BestFirst** busca en el espacio de subconjuntos de características mediante 'greedy hillclimbing' aumentada por una función de retroceso. Este método además necesita un evaluador llamado como **CfsSubsetEval** el cual evalúa el valor de un subconjunto de atributos al considerar la capacidad predictiva individual de cada característica junto con el grado de redundancia entre ellas. Al aplicar ambos algoritmos se consigue reducir el problema de clasificación a solo 23 características lo que permite aumentar el número de iteraciones de 50 a 500 (todos los experimentos siguientes serán con 500), puesto que al tener menos características a procesar se disminuye el tiempo de ejecución de los algoritmos, lo que permite tener mejores aproximaciones de la validación de Monte Carlo. Los resultados obtenidos son los siguientes:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	78.63	8.88	67.00	11.59	88.15	9.85
KNN	80.94	7.21	64.36	10.90	94.52	6.38
GB	80.08	8.48	70.60	11.97	87.84	9.35
LDA	80.64	8.34	72.87	11.39	87.01	8.58
MLP	78.23	10.46	72.69	14.79	82.77	17.71
SVM	84.64	7.61	75.60	10.64	92.05	7.67

Tabla 4.13: Validación cruzada, EQZ vs Control 256 Hz, con selección de 23 características.

En lugar de incluir las matrices de confusión del mejor y peor clasificador, ahora se incluyen gráficos estadísticos del mejor clasificador:



((a)) Evolución de porcentajes por iteración

((b)) Histograma de precisión

Figura 4.10: Gráficos de precisión conjunto 256 Hz, 23 características.

Al tener el apoyo visual de estos gráficos se puede apreciar de mejor manera la variación en los porcentajes de precisión obtenidos por el clasificador SVM, donde existe una mayor

cantidad de porcentajes mayores a 80 %. Estos resultados son los más altos conseguidos hasta el momento, alcanzó un máximo de precisión promedio de 84.64 % con desviación estándar de 7.61. También se lograron los más alto porcentajes promedio de sensibilidad y especificidad. Para verificar esta metodología de selección de características se realizó el mismo procedimiento esta vez con el conjunto de 128 Hz, reduciendo la cantidad de características de 1440 a 28:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	79.72	8.26	70.38	11.42	87.37	9.91
KNN	79.11	7.09	60.11	11.78	94.67	6.11
GB	79.67	7.63	68.56	12.13	88.77	8.86
LDA	82.93	8.05	76.69	10.43	88.04	8.91
MLP	79.06	9.14	71.07	14.34	85.61	13.81
SVM	83.95	7.56	75.98	10.37	90.48	8.77

Tabla 4.14: Validación cruzada, Esquizofrenia vs Control 128 Hz, con 28 características.

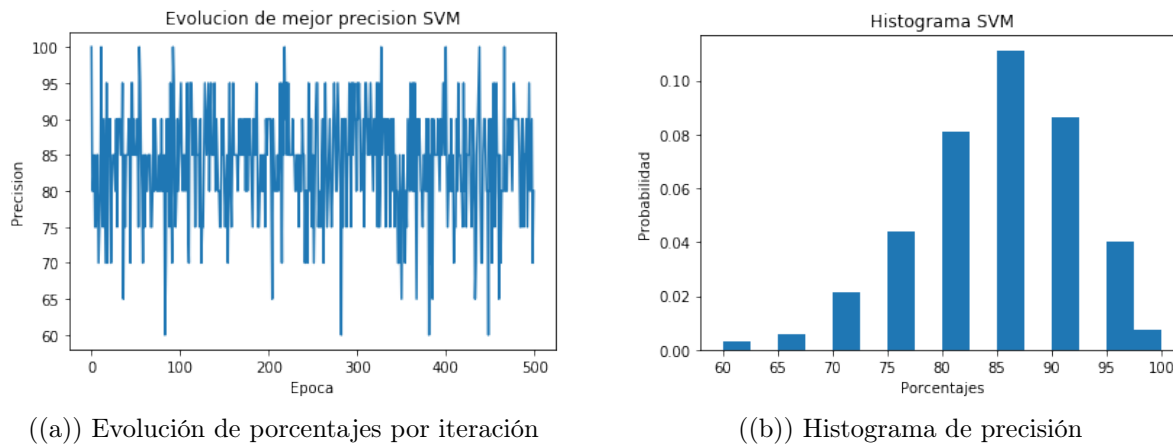


Figura 4.11: Gráficos de precisión conjunto 128 Hz, 28 características.

Para este conjunto se puede apreciar que los clasificadores RF, LDA, MLP y SVM pueden identificar de mejor forma los casos con esquizofrenia, puesto que sus sensibilidades promedio aumentaron, mientras que para los clasificadores KNN y GB este valor disminuyó. Por otro lado, la precisión promedio máxima del sistema en general disminuyó en 0.21 % puesto que se tienen mayores porcentajes inferiores a 80 % como indica el histograma.

4.3.6. Clasificación de otros conjuntos con selección

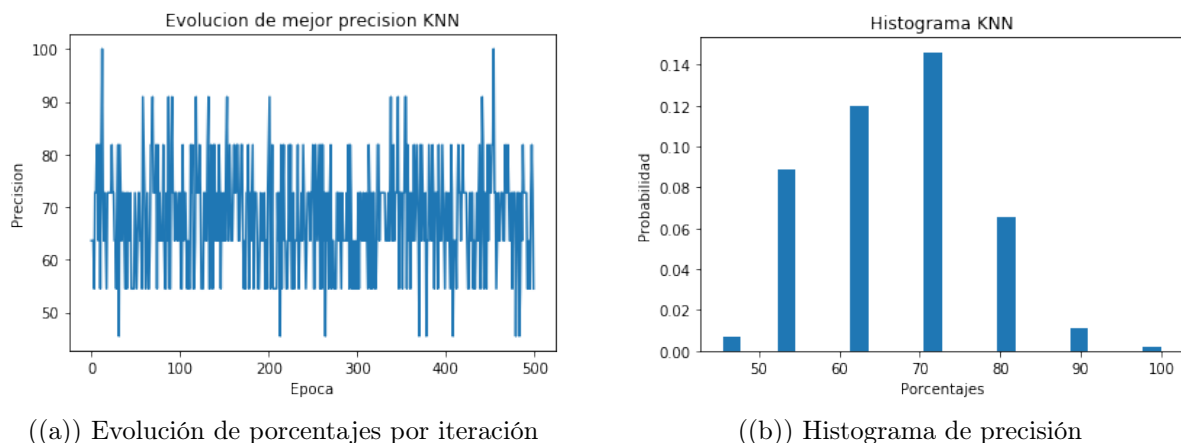
Ahora se presentarán los resultados de clasificación para las distintas separaciones de clases, considerando los 72 canales con selección de características para las bases de datos de 128 Hz y 256 Hz.

Problema binario APS vs CNTA

Los siguientes son resultados de diferenciación de síndrome de psicosis atenuada con respecto a adolescentes del grupo de control:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	67.95	8.20	87.30	10.90	16.46	22.46
KNN	68.04	10.17	85.85	10.51	20.66	25.29
GB	66.03	11.94	77.30	12.31	36.06	28.82
LDA	65.90	10.62	81.45	9.86	24.52	21.04
MLP	62.27	12.98	67.35	16.29	48.80	33.09
SVM	65.48	10.70	83.78	15.09	16.80	24.54

Tabla 4.15: Validación cruzada, APS vs CNTA 128 Hz, con selección de 4 características.



((a)) Evolución de porcentajes por iteración

((b)) Histograma de precisión

Figura 4.12: Gráficos de precisión APS vs CNTA, 128 Hz, 4 características.

Dados los resultados en el problema anterior, se esperaba que al comparar el grupo de control adolescente con APS se consiguieran resultados similares o mejores a CNTF vs EQZ puesto que los grupos CNTA y APS pertenecen al mismo grupo etario. Sin embargo, como lo demuestra la tabla estos resultados son inferiores, con la diferencia de los altos valores de sensibilidad y los bajos valores de especificidad. Esto último puede deberse a la poca cantidad de muestras del grupo CNTA que se encuentran en la base de datos, ya que puede significar que el clasificador no se entrenó lo suficiente con muestras de control, ya que existe tendencia a clasificar todas las muestras como APS. Se destaca que con apenas 4 características representativas por muestra se consiguen resultados de precisión promedio superiores a 62 %. Las 4

características filtradas son las siguientes: Movilidad de Hjorth del canal P3, dimensión Katz del canal Pz, dimensión Petrosian del canal PO8, y RIR de onda Alfa del canal EXG5. Por otro lado, los resultados de clasificación para el conjunto de 256 Hz son:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	78.31	8.52	96.80	6.31	29.06	25.03
KNN	71.35	7.20	92.43	8.39	15.26	19.32
GB	77.07	11.25	86.10	10.48	53.07	25.61
LDA	76.07	11.65	83.38	10.35	56.67	23.35
MLP	72.30	13.17	76.15	16.14	62.14	26.29
SVM	74.76	8.72	90.38	10.10	33.19	21.51

Tabla 4.16: Validación cruzada, APS vs CNTA 256 Hz, con selección de 5 características.

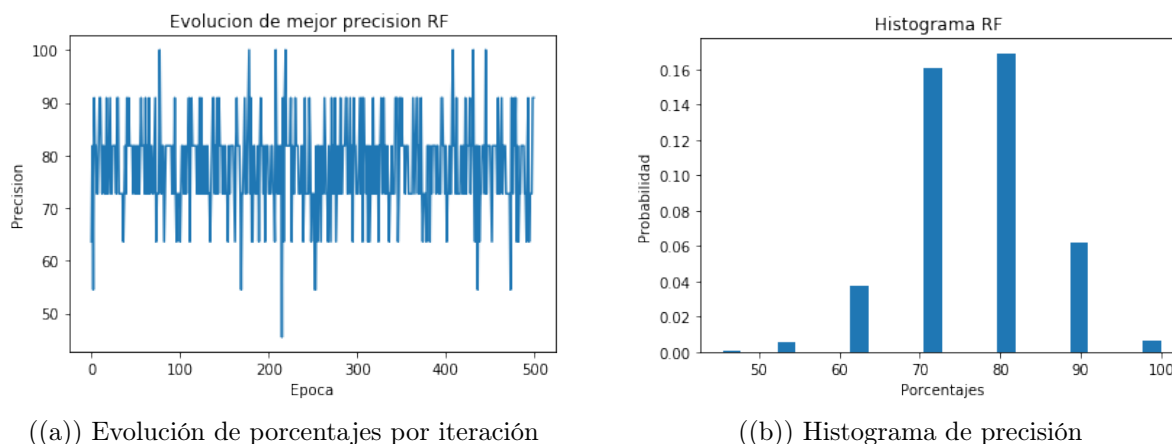


Figura 4.13: Gráficos de precisión APS vs CNTA, 256 Hz, 5 características.

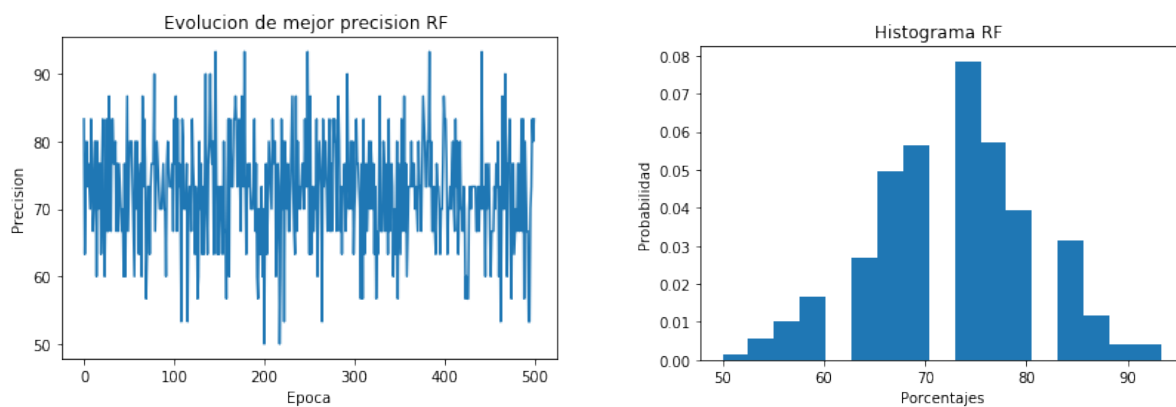
Utilizando solo 5 características se obtienen mejores resultados que el caso anterior, considerando que esta base de datos al ser de 256 Hz contiene más información que su par de 128 Hz. Sin embargo, para este caso también existe una alta sensibilidad y baja especificidad, que demuestra el efecto por la baja cantidad de muestras CNTA en los clasificadores. La alta precisión a pesar de la muy reducida cantidad de características puede deberse a que las señales CNTA no tienen suficiente diferenciación con las señales APS al extraer las 1440 características, lo que implica que la mayor parte de estas características no aportan información al clasificador. Las 5 características filtradas son las siguientes: dimensión Katz del canal P1, entropía espectral del canal P3, RIR de onda Theta de los canales P9 y PO3, y IPE de onda Theta del canal EXG5.

Problema binario Psicosis vs. Control

Ahora se presentan los resultados de clasificación al agrupar los casos con psicosis (APS, FEP y EQZ) con los casos de grupos de control (CNTA y CNTF) en solamente 2 conjuntos. Para la base de datos de 128 Hz se seleccionaron 23 características, resultando en lo siguiente:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	72.69	7.89	75.99	9.50	68.91	11.29
KNN	67.29	7.01	57.78	9.33	78.15	10.00
GB	69.23	8.05	70.11	10.73	68.23	12.70
LDA	71.18	7.66	67.14	8.58	75.80	9.52
MLP	67.51	8.36	66.98	13.32	68.13	15.34
SVM	72.27	7.37	73.67	9.11	70.65	10.48

Tabla 4.17: Validación cruzada, Psicosis vs Control 128 Hz, con 23 características.



((a)) Evolución de porcentajes por iteración

((b)) Histograma de precisión

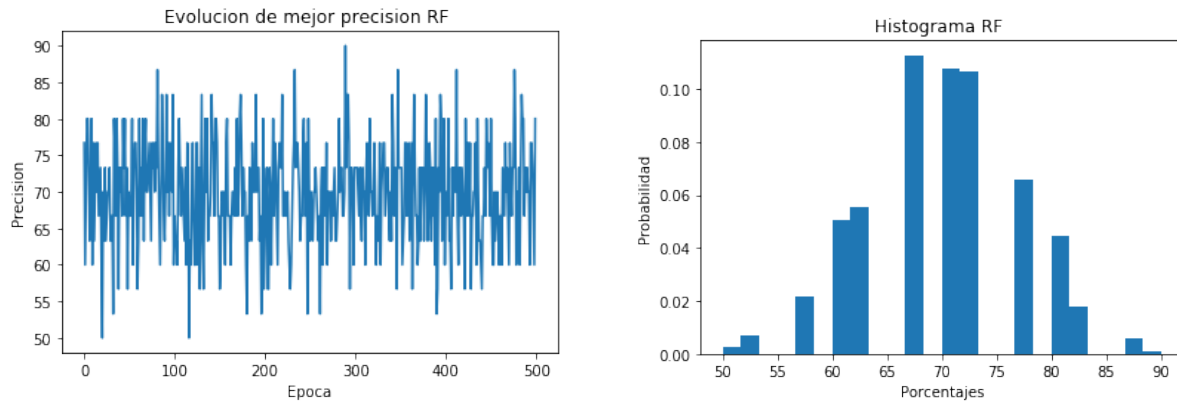
Figura 4.14: Gráficos de precisión Psicosis vs. Control, 128 Hz, 23 características.

Para este problema, teniendo en cuenta que existe una mayor cantidad de muestras de control adulto que de adolescente, se esperaban porcentajes de precisión promedio mayores o iguales a 70% lo que finalmente se ocurrió. Es importante notar que al tener una mayor variedad de muestras para entrenar los clasificadores también se necesitarán una mayor cantidad de características, donde en comparación al problema anterior aumentó de 4 a 23. Se pueden apreciar que los valores promedios de los porcentajes son coherentes entre sí, con los clasificadores RF y SVM con mayores sensibilidades promedio y, por otro lado, KNN y LDA con mayor especificidad. También es notable que el clasificador RF obtuvo una relativamente buena precisión promedio manteniendo un alto valor de sensibilidad promedio y valor de especificidad regular, de lo que se deduce que clasifica bien los casos con psicosis.

Luego, los resultados para el conjunto de 256 Hz para clasificación de psicosis y grupos de control son los siguientes:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	69.83	7.00	69.39	8.49	70.34	10.04
KNN	65.70	7.26	58.52	9.55	73.90	10.67
GB	65.30	7.66	65.76	10.54	64.78	12.24
LDA	69.51	6.75	69.16	7.24	69.92	9.25
MLP	65.65	7.44	64.19	12.19	67.31	13.04
SVM	69.19	6.96	65.76	7.41	73.11	9.99

Tabla 4.18: Validación cruzada, Psicosis vs Control 256 Hz, con 19 características.



((a)) Evolución de porcentajes por iteración

((b)) Histograma de precisión

Figura 4.15: Gráficos de precisión Psicosis vs Control, 256 Hz, 19 características.

Teniendo en consideración los problemas de clasificación con selección de características anteriores, se esperaba que al aumentar la frecuencia se obtuviesen mejores resultados, lo que no fue así ya que ningún clasificador logró superar una precisión promedio de 70%. A pesar de esto, los valores porcentuales promedio de las mediciones se mantienen similares entre sí para los 6 clasificadores, lo que implica que el problema es estable demostrado además por los gráficos, donde en el histograma se aprecia la forma de una Gaussiana centrada en aproximadamente en 70% de precisión.

Problema multiclase Control vs. APS vs. EQZ

Las figuras siguientes muestran los resultados obtenidos al tratar de clasificar síndrome de psicosis atenuada, esquizofrenia (FEP y EQZ) y grupo de control (CNTA y CNTF) con selección de características:

Clasificador	Precisión 128 Hz [%]		Precisión 256 Hz [%]	
	\bar{x}	σ	\bar{x}	σ
RF	57.58	7.17	58.41	7.36
KNN	51.56	5.91	55.72	5.15
GB	57.53	7.73	56.73	8.50
LDA	60.21	7.46	59.33	7.58
MLP	51.52	8.97	53.91	8.94
SVM	58.25	6.46	61.11	5.58

Tabla 4.19: Validación cruzada, problema de 3 clases, ambos conjuntos.

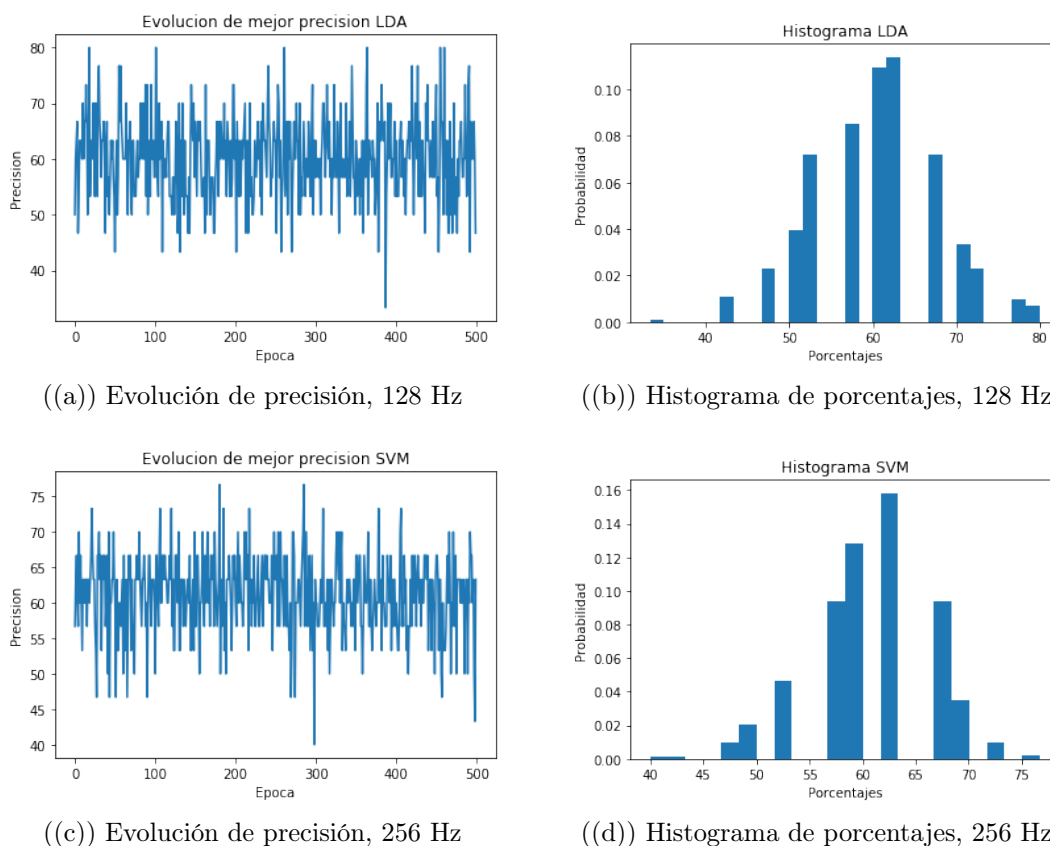


Figura 4.16: Gráficos para problema de 3 clases.

Para el primer problema de clasificación multiclase se aprecian bajos valores promedios, considerando la selección de 20 características para las muestras de 128 Hz y 13 para las de 256 Hz. Se aprecia que el conjunto de 256 Hz tiene la mayor precisión promedio obtenida por SVM, con baja desviación estándar, pero el conjunto de 128 Hz alcanzó mayores precisiones máximas llegando a 80 % mientras que el de 256 Hz llega a 77 % aproximadamente. La mayor cantidad de datos se ubica en torno a 55 % y 70 % para ambos conjuntos.

Problema de 5 clases por separado

Clasificador	Precisión 128 Hz [%]		Precisión 256 Hz [%]	
	\bar{x}	σ	\bar{x}	σ
RF	51.24	6.15	50.67	6.22
KNN	45.20	6.31	46.72	6.30
GB	45.81	7.82	48.05	7.49
LDA	47.51	5.99	48.84	6.80
MLP	40.51	9.42	41.39	9.56
SVM	48.16	5.21	52.68	5.77

Tabla 4.20: Validación cruzada, problema de 5 clases, ambos conjuntos.

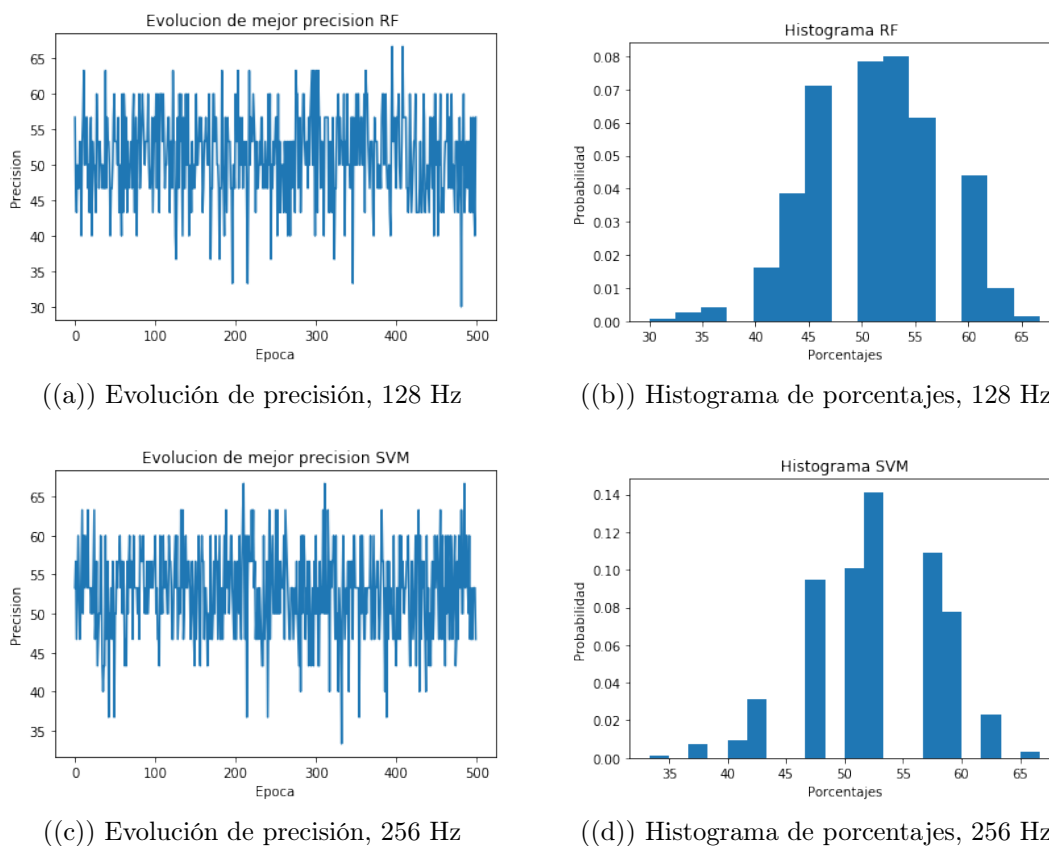


Figura 4.17: Gráficos para problema de 5 clases.

Para el segundo problema multiclase, se consiguieron valores inferiores al problema de 3 clases, no llegando a superar el 53% de precisión promedio. Al contrario de los problemas anteriores, aquí el conjunto de 256 Hz supera en general el rendimiento del conjunto de 128 Hz. De los gráficos se extrae que la máxima precisión promedio alcanzada es 66% mientras que la mínima es de 30%, mientras que la mayor cantidad de datos se encuentra entre 50 y 60% de precisión, lo que es sumamente bajo comparado a los otros resultados, especialmente los casos binarios. Por otro lado, este problema presenta bajas desviaciones estándar para todos los clasificadores, lo que demuestra alta consistencia de los resultados.

4.4. Clasificación de datos usando tarea Double Flash


Debido a que los datos de la tarea Double Flash tenían mayor tamaño en disco y poseían menos muestras que la tarea Resting State, en la etapa de procesamiento de señales antes de aplicar los filtros pasabanda (*filtfilt* y *eegfilt*) se submuestra la señal de 2048 Hz a 256 Hz, con tal de reducir el tamaño de las señales y por ende el tiempo de procesamiento de los filtros y la eliminación de artefactos. Para este caso no se realizó procesamiento a 128 Hz puesto que se demostró en los experimentos anteriores del conjunto Resting State se obtienen resultados de precisión inferiores a los conjuntos de 256 Hz. Siguiendo la metodología de extracción de 1440 características y validación cruzada de Monte Carlo de 50 iteraciones se obtuvieron los siguientes resultados:

4.4.1. Clasificación de esquizofrenia sin selección

Las siguientes figuras son los resultados obtenidos para el conjunto Double Flash usando el filtro *filtfilt* más algoritmo ICA:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	63.57	14.77	57.00	18.06	68.80	18.83
KNN	62.02	12.20	32.50	20.77	85.60	15.51
GB	66.02	14.48	53.00	21.00	76.40	18.63
LDA	69.14	15.12	60.00	18.03	76.40	16.82
MLP	67.58	14.37	61.00	19.47	72.80	20.69
SVM	71.80	14.09	58.50	17.04	82.40	18.61

Tabla 4.21: Validación cruzada, tarea DBF, filtro *filtfilt*.



((a)) Evolución de porcentajes por iteración

((b)) Histograma de precisión

Figura 4.18: Gráficos de precisión EQZ vs Control, tarea DBF filtro *filtfilt*.


Para esta base de datos se aprecia porcentajes de precisión inferiores a la metodología respectiva en la base de datos de Resting State presente en la tabla 4.1, con una diferencia

porcentual considerable de 5%. También es de notar los altos valores de desviación estándar para las 3 mediciones lo que implica en una alta variación en los porcentajes con cada iteración del algoritmo, que también se aprecia en el gráfico de evolución de porcentajes.

Por otro lado, los resultados utilizando el filtro *eegfilt* más ICA son los siguientes:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	57.79	15.42	47.00	19.77	66.40	18.08
KNN	61.57	14.11	35.50	21.85	82.40	19.86
GB	64.02	15.01	53.00	20.40	72.80	18.66
LDA	67.81	12.02	58.50	18.45	75.20	14.18
MLP	64.02	13.44	56.50	22.81	70.00	18.87
SVM	70.69	11.71	54.50	16.35	83.60	16.34

Tabla 4.22: Validación cruzada, tarea DBF, metodología *eegfilt*.



((a)) Evolución de porcentajes por iteración

((b)) Histograma de precisión

Figura 4.19: Gráficos de precisión EQZ vs Control, tarea DBF filtro *eegfilt*.

Para el caso del filtro *eegfilt*, se obtienen porcentajes promedios inferiores en comparación a utilizar el filtro *filtfilt*, que es congruente con lo obtenido en las tablas 4.1 y 4.2 donde el conjunto procesado con *filtfilt* entrega mejores resultados de clasificación que el conjunto *eegfilt*. Sin embargo, para la tarea Double Flash en ambos conjuntos se aprecia alta variabilidad en las sensibilidades promedios, lo que se puede traducir en problemas al caracterizar las muestras con esquizofrenia.

4.4.2. Clasificación de EQZ con selección de características

A continuación, se presentarán los resultados obtenidos al aplicar el algoritmo de selección de características de WEKA sobre las bases de datos usadas anteriormente. Dado que se tienen menor características, se procede a aumentar el número de iteraciones de la validación de Monte Carlo a 500, obteniendo lo siguiente para el método *filtfilt* más ICA:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	73.02	13.57	64.85	20.51	79.52	15.84
KNN	79.51	8.76	57.60	16.19	97.00	7.58
GB	83.37	12.15	75.10	19.68	89.96	13.71
LDA	84.19	10.76	78.25	15.83	88.92	11.92
MLP	86.70	12.30	86.30	19.36	87.00	16.96
SVM	87.10	10.78	84.45	16.72	89.20	12.72

Tabla 4.23: Validación cruzada, DBF *filtfilt* con 18 características.

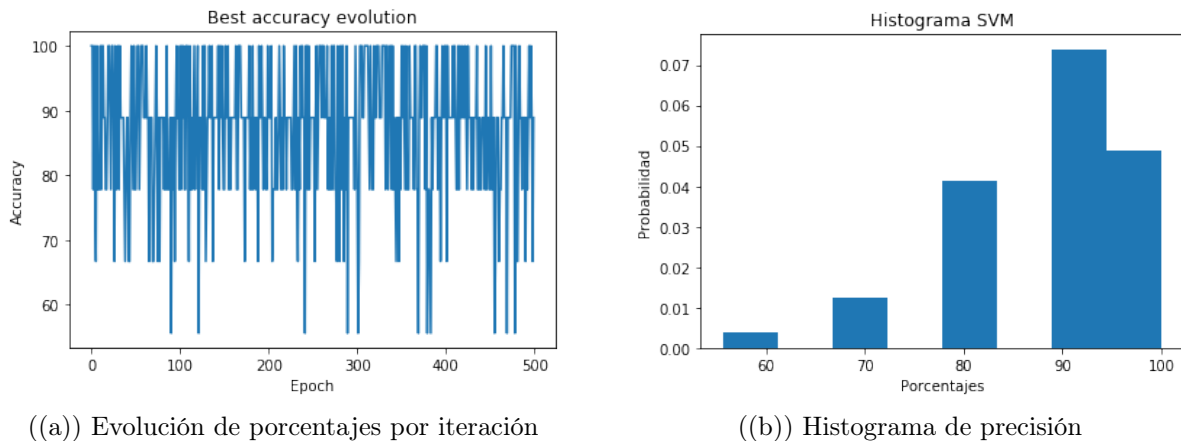


Figura 4.20: Gráficos EQZ vs Control, tarea DBF eegfilt con 18 características.

Al aplicar el algoritmo de selección además de reducir considerablemente la cantidad de características a procesar, también aumento de forma drástica los valores porcentuales promedio de las 3 mediciones, alcanzando el mayor valor de precisión promedio obtenido hasta ahora de 87.10% para el clasificador Support Vector Machine, con una alta tendencia a valores sobre 85% de precisión y una gran cantidad de iteraciones con precisión perfecta de 100%. También se obtuvo el mejor par de sensibilidad y especificidad promedio de 86.3% y 87%, respectivamente, para el clasificador Multi-Layer Perceptron.

Teniendo esto, los resultados para el conjunto filtrado con *eegfilt* son los siguientes, logrando reducir con WEKA de 1440 a 17 características:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	76.46	15.21	68.20	20.22	83.04	16.74
KNN	74.20	10.37	48.50	18.45	94.72	9.68
GB	85.37	11.41	78.70	17.93	90.68	12.91
LDA	79.31	12.45	72.80	19.11	84.48	13.47
MLP	73.75	13.24	69.30	20.43	77.28	18.43
SVM	80.37	12.71	74.90	16.96	84.72	15.02

Tabla 4.24: Validación cruzada, DBF *eegfilt* con 17 características.

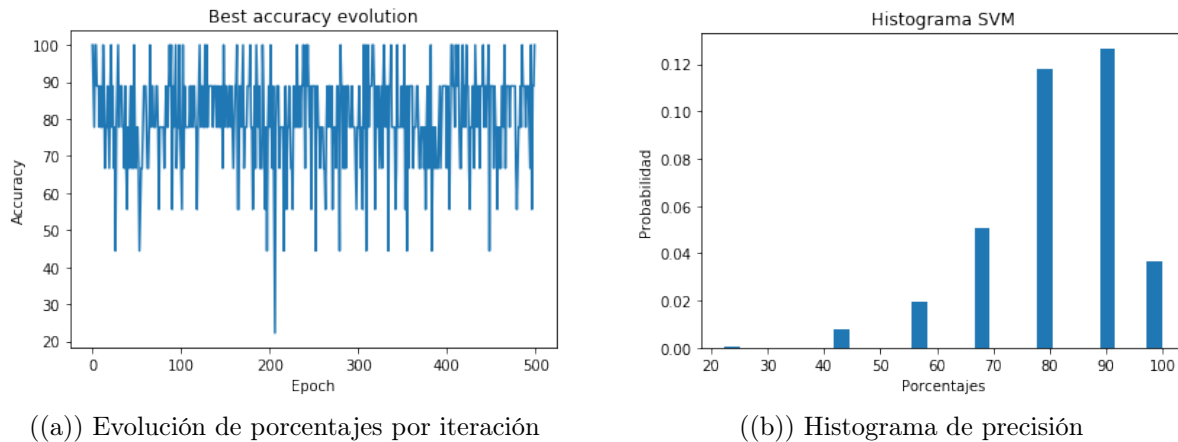


Figura 4.21: Gráficos EQZ vs Control, tarea DBF *eegfilt* con 17 características.

Al igual que el experimento anterior se aprecia una mejora sustancial en los resultados de clasificación, alcanzando una precisión promedio de 85.37% para el clasificador Gradient Boosting con la mejor relación entre sensibilidad y especificidad, junto con una tendencia a obtener valores de precisión mayores a 80%. A pesar de esto, queda claro que la metodología de aplicar el filtro *eegfilt* de la librería EEGLAB es inferior a aplicar el filtro *filtfilt* por defecto de Matlab, además de ser más rápido para procesar las señales.

4.4.3. Clasificación binaria de psicosis

En la siguiente tabla se presentan los resultados de clasificación al agrupar los conjuntos APS, FEP y EQZ como clase Psicosis y los conjuntos CNTA y CNTF como clase Control. Se omitió el análisis de resultados mediante filtro *eegfilt* ya que se obtiene peor rendimiento que utilizar *filtfilt*. Los primeros análisis serán sobre los resultados obtenidos por el sistema de clasificación sin selección de características y 50 iteraciones:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	71.85	9.84	82.02	9.65	53.60	21.33
KNN	70.28	8.38	90.90	11.25	33.20	22.13
GB	69.14	9.53	85.79	9.16	39.20	19.17
LDA	73.00	10.25	75.80	9.34	68.00	17.44
MLP	70.43	10.60	66.03	18.11	78.40	21.85
SVM	67.99	7.04	93.34	10.17	22.40	17.27

Tabla 4.25: Validación cruzada, Psicosis vs Control, tarea DBF.

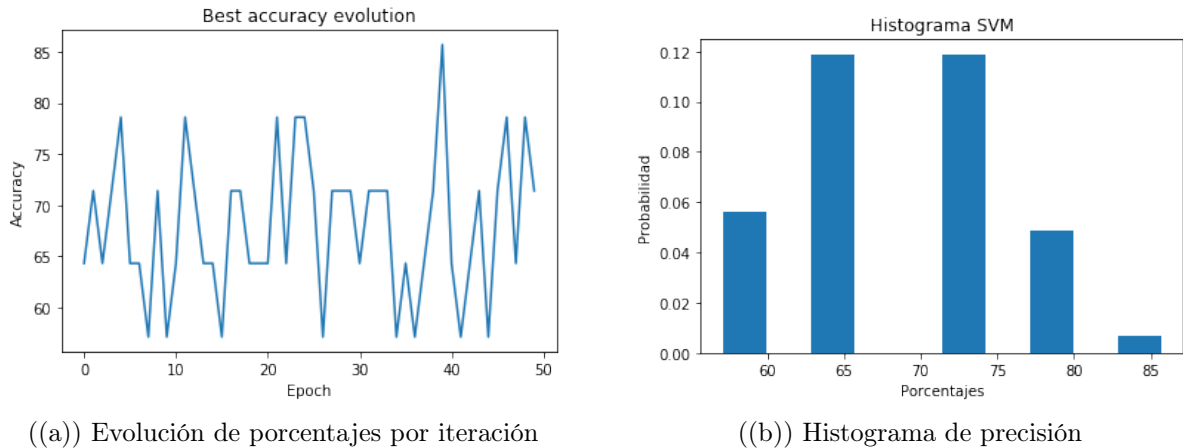


Figura 4.22: Gráficos de precisión, Psicosis vs Control, tarea DBF.

Comparando estos resultados con sus pares anteriores, se aprecia que se obtienen mejores valores de precisión promedio por lo general, lo que implica que al tener más muestras en el sistema de clasificación se logra una mejor diferenciación de las clases que los experimentos anteriores, tanto Double Flash como Resting State. Se aprecia además una gran variación en los valores de especificidad al tener altas desviaciones estándar y bajos valores promedios mientras que ocurre lo contrario para la sensibilidad, lo que demuestra que el sistema clasifica mejor los casos con psicosis que los casos sanos del grupo de control.

4.4.4. Clasificación de psicosis con selección de características

Por otro lado, al procesar los datos en el algoritmo de selección de WEKA se logra reducir de 1440 a 26 características y aumentando el número de iteraciones de Monte Carlo a 500, obteniendo los siguientes resultados:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	82.85	11.80	88.94	10.03	71.88	22.74
KNN	83.91	8.70	80.60	9.91	89.88	13.18
GB	82.24	10.67	88.19	9.47	71.52	21.62
LDA	85.47	8.55	81.75	10.06	92.16	11.63
MLP	84.61	11.31	84.21	15.60	85.32	17.52
SVM	88.78	7.99	91.08	8.55	84.64	14.62

Tabla 4.26: Validación cruzada, Psicosis vs Control, DBF 26 características.

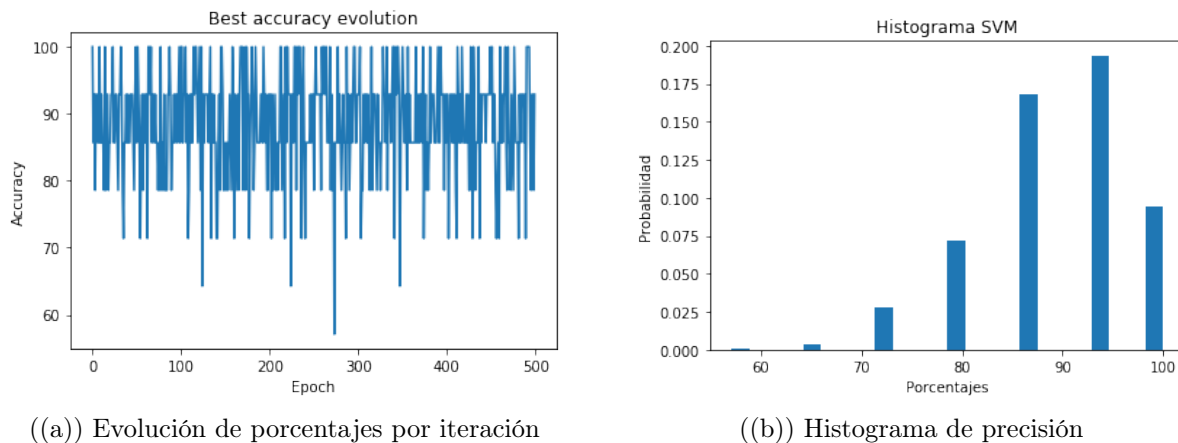


Figura 4.23: Gráficos de precisión, Psicosis vs Control, tarea DBF con 26 características.

Estos resultados corresponden a los mejores obtenidos de todos los otros experimentos de clasificación binaria, con un valor promedio máximo de precisión igual a 88.78% con sensibilidad de 91.08% y especificidad de 84.64%, los cuales tienen baja desviación estándar lo que implica que los valores reales de precisión y sensibilidad son cercanos a estos valores promedio máximos, obtenidos por Support Vector Machine por sobre los otros clasificadores. De los gráficos se extrae que la mayoría de los porcentajes obtenidos por el sistema de clasificación son mayores a 85%, lo que implica que son muy buenos resultados.

4.5. Clasificación de datos usando tarea Sternberg


Para el caso de la base de datos de la tarea Sternberg, no se presentan muestras etiquetadas como esquizofrenia, por lo que solo se plantearán problemas de clasificación binarios analizando FEP, APS y APS junto a FEP (Psicosis) versus los pacientes del grupo de control. Además, teniendo en cuenta los resultados obtenidos por las bases de datos Resting State y Double Flash, no se presentarán resultados usando frecuencia de muestreo de 128 Hz ni filtro *eegfilt*, puesto que entregan resultados de precisión inferiores.

4.5.1. Clasificación de FEP sin selección

En este experimento se realizó la clasificación de las muestras FEP y las muestras del grupo de control adulto, sin selección de características, obteniendo los siguientes resultados:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	61.97	13.19	62.60	14.33	62.21	20.16
KNN	53.81	12.41	45.93	17.31	62.80	19.96
GB	60.89	12.35	61.07	17.01	61.94	22.62
LDA	58.89	11.37	57.81	11.55	60.34	15.51
MLP	60.53	11.85	58.07	16.20	63.34	17.27
SVM	60.71	12.64	53.06	16.48	69.87	19.82

Tabla 4.27: Validación cruzada, FEP vs CNTF, Sternberg.



((a)) Evolución de porcentajes por iteración

((b)) Histograma de precisión

Figura 4.24: Gráficos de precisión, FEP vs CNTF, tarea Sternberg.

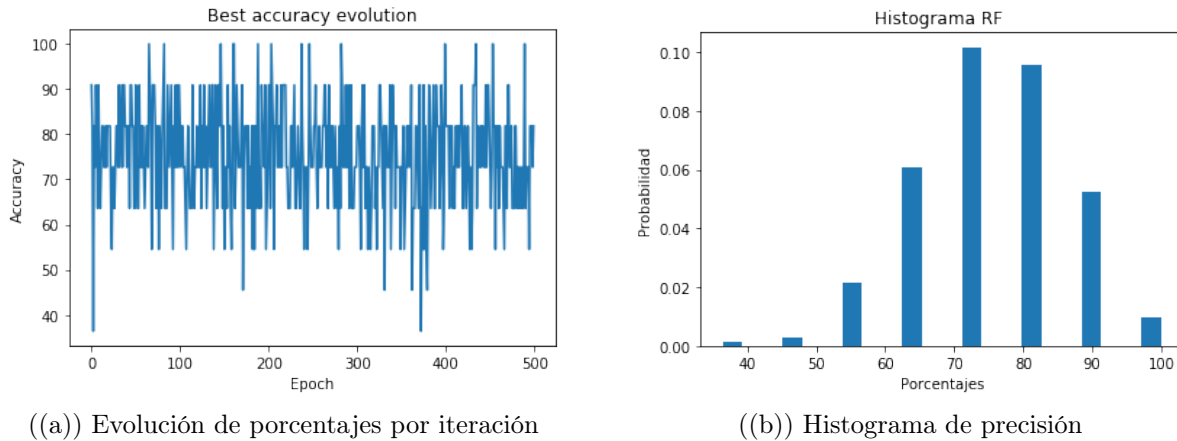
Se aprecia que los resultados de clasificación tienen bajos valores de precisión, e inferiores comparados con los datos de la tabla 4.21. De los gráficos se puede notar que pocas veces se alcanzó una precisión mayor a 80 %, donde la mayoría de los porcentajes se encuentran alrededor del 60 %, lo que es deficiente, pero destacando que todos los clasificadores tienen desempeños similares, con excepción de KNN.

4.5.2. Clasificación de FEP con selección de características

Por otro lado, usando el programa WEKA para reducir características y al igual que las otras bases de datos, se obtienen mejores resultados reduciendo de 1440 a 12 características:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	75.65	11.47	72.98	14.62	79.15	16.45
KNN	70.88	12.23	61.20	16.38	81.69	17.84
GB	74.45	11.59	70.95	15.41	78.80	15.81
LDA	74.25	11.88	68.23	14.05	80.82	14.38
MLP	69.61	13.16	66.65	15.65	73.29	22.37
SVM	70.92	11.39	64.27	14.04	78.48	17.91

Tabla 4.28: Validación cruzada, FEP vs CNTF, Sternberg con 12 características.



((a)) Evolución de porcentajes por iteración

((b)) Histograma de precisión

Figura 4.25: Gráficos de precisión, FEP vs CNTF, tarea Sternberg con 12 características.


En este caso se obtiene una mejora substancial en los porcentajes, con incrementos mayores a 15 % de precisión promedio llegando a 75.65 % usando RandomForest, que es un resultado moderado pero inferior a lo obtenido por las bases de datos, notando además el bajo porcentaje de sensibilidad. Analizando los gráficos se aprecia que la mayoría de los porcentajes es mayor a 70 %. Por otro lado, si se considera que Sternberg no presenta muestras de esquizofrenia, como las otras tareas, podría implicar que el conjunto FEP en este caso no se diferencia lo suficiente del grupo de control, o en menor medida con respecto al conjunto EQZ.

4.5.3. Clasificación de APS sin selección

Para este problema se clasificará el conjunto APS con respecto a los pacientes del grupo de control adolescente, destacando que tiene una cantidad similar de muestras que el conjunto FEP, entregando los siguientes resultados de clasificación:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	63.80	11.30	85.66	12.91	19.99	19.99
KNN	69.36	6.10	98.66	4.53	10.66	15.53
GB	65.36	12.70	88.99	12.29	17.99	22.32
LDA	69.14	14.10	79.00	12.37	49.33	27.70
MLP	67.58	15.53	66.33	17.78	70.01	26.04
SVM	66.48	1.55	99.67	2.34	0.00	0.00

Tabla 4.29: Validación cruzada, APS vs CNTA, tarea Sternberg.



((a)) Evolución de porcentajes por iteración

((b)) Histograma de precisión

Figura 4.26: Gráficos de precisión, APS vs CNTA, tarea Sternberg.


Se puede observar que este conjunto tiene mejores resultados que los anteriores, y con resultados de precisión promedio similares a los de la tabla 4.21. Se aprecian, además, altos valores de sensibilidad y bajos valores de especificidad, indicando tendencia a etiquetar todo como APS. De los gráficos, se obtiene baja variabilidad de porcentajes, centrándose solo en 3 valores porcentuales, lo que indica podría existir sobreajuste de los datos.

4.5.4. Clasificación de APS con selección de características

Al disminuir de 1440 a 11 características, se obtienen incrementos en los porcentajes de forma general, lo que implica en la obtención de mejores resultados que el caso anterior:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	80.64	10.87	96.49	7.27	48.86	28.71
KNN	77.56	8.20	99.63	2.45	33.32	24.50
GB	82.95	12.08	91.16	10.66	66.47	27.86
LDA	90.54	8.23	89.29	10.52	93.01	14.52
MLP	86.77	13.16	86.12	17.19	88.01	20.82
SVM	87.08	9.32	97.23	6.21	66.74	27.13

Tabla 4.30: Validación cruzada, APS vs CNTA, tarea Sternberg con 11 características.



((a)) Evolución de porcentajes por iteración

((b)) Histograma de precisión

Figura 4.27: Gráficos de precisión, APS vs CNTA, tarea Sternberg con 11 características.


Para este caso, el clasificador LDA obtuvo la precisión promedio más alta vista hasta ahora, con 90.54 %, superando a la clasificación de psicosis del conjunto Double Flash con 88.78 %, obtenido por SVM. Además, LDA obtienen excelentes valores de sensibilidad y especificidad promedio, con una desviación estándar (dispersión de porcentajes) relativamente baja. De los gráficos se aprecia que la mayor cantidad de porcentajes obtenidos se encuentra sobre el 85 % con gran cantidad acercándose a 10 %, lo que es un resultado muy positivo. Sin embargo, resulta curioso que el conjunto APS que en teoría tiene menor diferenciación al grupo de control, obtenga mejores resultados de clasificación que el conjunto FEP, el cual debiera tener mayor diferenciación.

4.5.5. Clasificación de psicosis sin selección

Para este experimento y al igual que las bases de datos anteriores, se etiquetaron los conjuntos APS y FEP como una sola clase y se compararon con respecto al grupo de control CNTF y CNTA combinado, obteniendo los siguientes resultados de clasificación:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	62.00	9.00	74.00	11.50	44.00	15.46
KNN	58.40	9.19	74.50	14.48	34.25	16.17
GB	57.30	9.91	67.34	12.22	42.25	16.75
LDA	61.50	8.96	65.00	10.01	56.25	13.29
MLP	56.80	9.15	57.99	14.71	55.00	16.58
SVM	57.80	7.08	85.00	11.90	17.00	13.41

Tabla 4.31: Validación cruzada, Psicosis vs Control, tarea Sternberg.



((a)) Evolución de porcentajes por iteración

((b)) Histograma de precisión

Figura 4.28: Gráficos de precisión, Psicosis vs Control, tarea Sternberg

De la tabla se aprecia la obtención de algunos resultados inferiores a la tabla 4.27, siendo que uno esperaría que fueran resultados intermedios entre la tabla 4.27 y la tabla 4.29, puesto que se tienen conjuntos combinados lo que no fue así. Se notan además bajos valores de especificidad, mostrando una tendencia del sistema a clasificar más datos como psicosis que control. Por otro lado, en los gráficos se observa una alta variación en los porcentajes de precisión, con un rango entre 35 % y 80 %. Estos datos implican que las muestras FEP afectan de forma importante los resultados de clasificación y puede que no sean lo suficientemente diferentes a las muestras con APS y las del grupo de control.

4.5.6. Clasificación de psicosis con selección de características

En tanto, al reducir la cantidad de características usando WEKA se obtienen mejores resultados que el caso sin selección, pero aun así son inferiores a los de la tabla 4.28, demostrando aún más que las muestras FEP influyen negativamente en el sistema de clasificación. Además, en los gráficos se aprecia la misma tendencia de alta variabilidad de porcentajes:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	71.60	10.32	76.83	10.60	63.75	16.15
KNN	62.52	9.52	55.76	11.72	72.65	14.06
GB	68.33	10.25	71.25	11.46	63.95	16.41
LDA	62.70	10.08	67.28	9.86	55.83	14.32
MLP	61.67	10.28	63.12	13.53	59.50	17.35
SVM	68.05	9.14	72.83	9.83	60.88	16.09

Tabla 4.32: Validación cruzada, Psicosis vs Control, tarea Sternberg con 11 características.

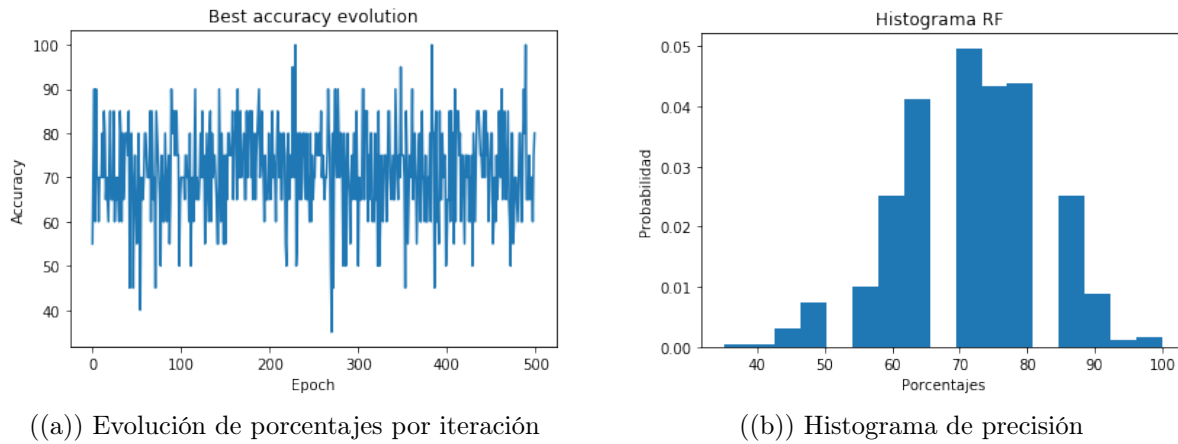


Figura 4.29: Gráficos de precisión, Psicosis vs Control, tarea Sternberg con 11 características.

4.6. Clasificación de datos usando tarea Moving Dots


La tarea Moving Dots (MVD) tiene una cantidad reducida de muestras comparada con las otras bases de datos, por lo que en este caso solo se hará el problema de clasificación binario de psicosis juntando las muestras APS con la única muestra FEP y combinando CNTA y CNTF. Al igual que Sternberg, se omite el uso de la frecuencia 128 Hz y filtro eegfilt.

4.6.1. Clasificación de psicosis sin selección

Los resultados de clasificación de psicosis (APS y FEP) sin selección de características son los siguientes:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	60.52	9.88	33.20	15.29	83.33	14.13
KNN	50.90	8.69	16.40	17.75	79.66	14.24
GB	53.26	12.70	26.80	17.71	75.33	18.02
LDA	61.98	13.79	50.40	15.62	71.66	16.40
MLP	60.89	14.21	55.60	20.51	65.33	19.67
SVM	53.96	3.34	1.20	4.75	98.00	5.43

Tabla 4.33: Validación cruzada, Psicosis vs Control, tarea Moving Dots.



((a)) Evolución de porcentajes por iteración

((b)) Histograma de precisión

Figura 4.30: Gráficos de precisión, Psicosis vs Control, tarea Moving Dots.

En este caso se tienen porcentajes de precisión promedio inferiores su correspondiente experimento en la base de datos Sternberg, con la particularidad de ahora son los porcentajes de sensibilidad los que tienen valores muy bajos en lugar de los porcentajes de especificidad. Esto significa que el sistema está clasificando casi todas las muestras como grupo de control. También se tienen altos valores de desviación estándar lo que se refleja en lo obtenido por los gráficos, ya que presentan alta variabilidad o dispersión en los porcentajes de precisión.

4.6.2. Clasificación de psicosis con selección de características

Ahora se presentarán los resultados de clasificación reduciendo de 1440 a 13 características, obteniendo lo siguiente:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	79.83	12.32	66.88	23.71	90.65	9.76
KNN	82.09	7.95	98.44	7.04	68.51	13.34
GB	83.55	11.14	74.80	20.56	90.85	10.06
LDA	85.39	9.24	89.44	13.46	82.02	11.04
MLP	80.98	11.21	74.24	19.07	86.62	15.23
SVM	79.78	9.75	75.88	18.33	83.06	13.49

Tabla 4.34: Validación cruzada, Psicosis vs Control, tarea Moving Dots con 13 características.

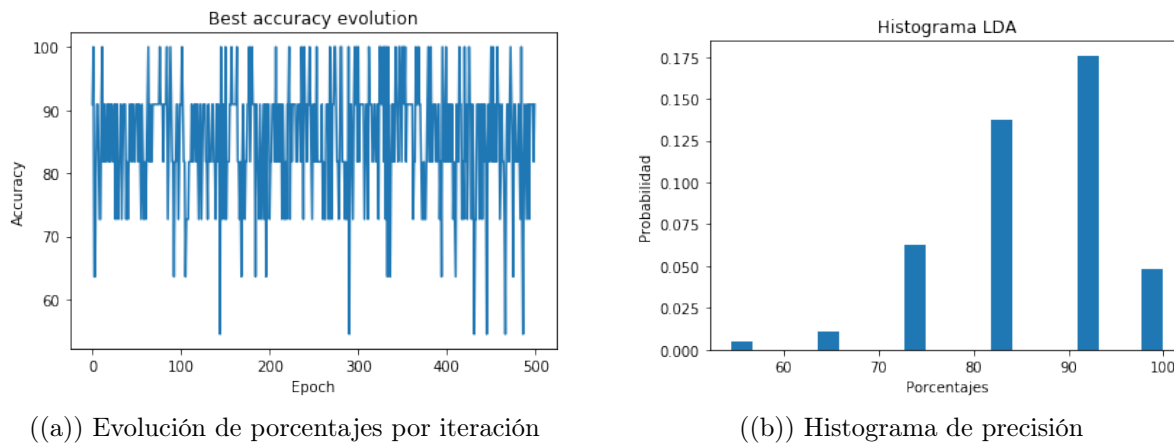


Figura 4.31: Gráficos de precisión, Psicosis vs Control, tarea Moving Dots con 13 características.

Al contrario que lo obtenido en la tarea STB, al clasificar psicosis con reducción de características y usando clasificador LDA se obtienen porcentajes mayoritariamente sobre el 80%, siendo la mayor cantidad de porcentajes obtenidos alrededor de 90%, según los gráficos. Sin embargo, dado que existe solamente una muestra etiquetada como FEP, este problema binario consiste básicamente en la clasificación de APS vs. Grupo de control, por lo que sería más correcto compararlo con los datos de la tabla 4.30 notando que se obtienen resultados inferiores pero similares, con una precisión promedio máxima de 85.39%.

4.7. Clasificación de datos usando tarea MMN Emocional

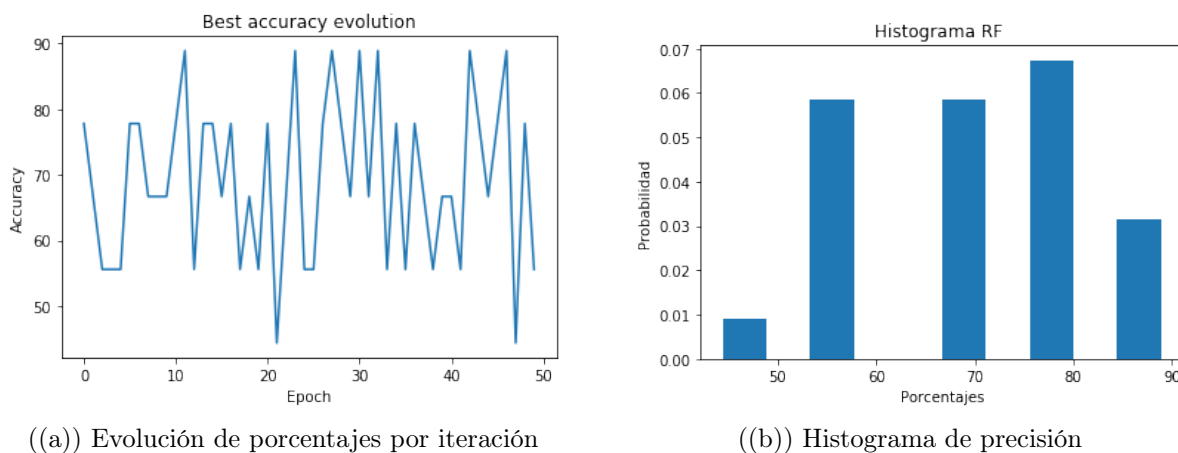
Al igual que la tarea anterior, la base de datos MMN Emocional es la que tiene la menor cantidad de muestras sin contener etiquetas de tipo FEP o EQZ, por lo que solo será posible realizar la comparación entre APS y el grupo de control siguiendo la misma metodología de los conjuntos anteriores.

4.7.1. Clasificación de APS sin selección

Los resultados de clasificación sin selección de características para el conjunto MMN Emocional son los siguientes:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	69.36	12.28	41.99	19.81	82.99	13.11
KNN	67.37	6.44	6.00	14.43	98.00	5.43
GB	66.03	11.20	21.99	24.59	87.99	11.07
LDA	62.24	13.35	42.00	23.88	72.34	12.28
MLP	56.23	12.68	50.67	25.18	59.01	15.71
SVM	65.59	3.33	0.00	0.00	98.33	5.01

Tabla 4.35: Validación cruzada, APS vs Control, tarea MMN Emocional.



((a)) Evolución de porcentajes por iteración

((b)) Histograma de precisión

Figura 4.32: Gráficos de precisión, APS vs Control, tarea MMN Emocional.

De los datos presentes en la tabla, se aprecia que ocurre algo similar a la tabla 4.33 de Moving Dots, donde hay alta variabilidad de los porcentajes de precisión y bajos valores de sensibilidad promedio, llegando incluso a 0% para el clasificador SVM, lo que significa que el sistema clasifica las muestras solamente como grupo de control. En los gráficos además se aprecia que la mayor parte de las precisiones promedio se encuentra entre 50% y 80%.

4.7.2. Clasificación de APS con selección de características

Por último, al reducir de 1440 a 12 características el problema anterior obtiene mejores resultados de clasificación:

Clasificador	Precisión [%]		Sensibilidad [%]		Especificidad [%]	
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ
RF	86.04	11.14	74.15	21.24	91.95	9.92
KNN	84.82	11.47	67.01	24.00	93.69	8.23
GB	86.72	11.61	74.47	24.48	92.82	8.72
LDA	83.15	10.89	75.48	22.67	86.95	9.87
MLP	79.66	13.03	81.81	22.40	78.56	16.15
SVM	82.51	11.21	69.48	22.44	88.98	10.01

Tabla 4.36: Validación cruzada, APS vs Control, MMN Emocional con 12 características.

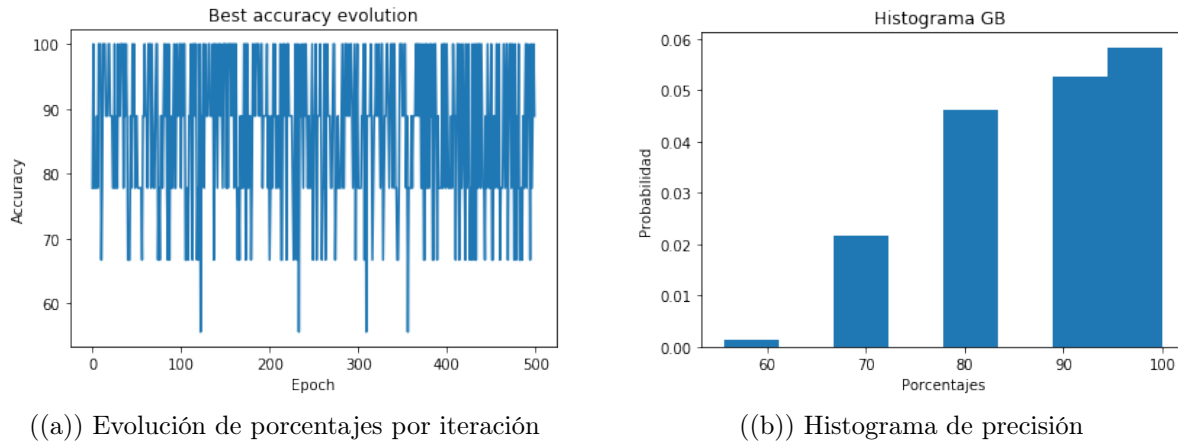



Figura 4.33: Gráficos de precisión, APS vs Control, tarea MMN Emocional con 12 características.

Al contrario de las tareas anteriores, el clasificador que obtuvo la más alta precisión promedio corresponde a Gradient Boosting con 86.72%. Sin embargo, su valor de sensibilidad promedio es 18.35% más bajo que la especificidad promedio, y además la desviación estándar de la sensibilidad tiene un valor de 24.48, que es de lo más alto vistos durante los experimentos. De los gráficos se evidencia que el sistema tiende a clasificar correctamente sobre el 75% de las muestras, pero es mejor clasificando muestras del grupo de control que las de APS.


4.8. Análisis clínico y técnico de características

4.8.1. Conjuntos Resting State y Double Flash


En esta sección se analizarán las características que fueron seleccionadas por el programa WEKA para los casos que obtuvieron mejores resultados (mayor a 80 %): EQZ vs Control de Resting State (128 y 256 Hz), EQZ vs Control de Double Flash, y Psicosis vs Control de Double Flash. Para estos conjuntos, las características seleccionadas se identifican según las siguientes distribuciones de electrodos EEG:




((a)) EQZ vs Control 128 Hz, Resting State



((b)) EQZ vs Control 256 Hz, Resting State



((c)) EQZ vs Control, Double Flash



((d)) Psicosis vs Control, Double Flash

Figura 4.34: Asociación de características a distribución de electrodos, RS y DBF.

En las figuras, los nodos naranjos indican que más de una característica está asociada a tal electrodo. Extendiendo estas distribuciones de nodos a la corteza cerebral¹, primero se tiene que el cerebro esta formado por 2 hemisferios con 4 lóbulos cada uno:

¹Brain lobes, Mayo Clinic <https://www.mayoclinic.org/brain-lobes/img-20008887>




Figura 4.35: Lóbulos del cerebro

Donde cada lóbulo está relacionado a una función corporal²:

- Lóbulo frontal: ayuda a controlar los movimientos musculares voluntarios, el estado de ánimo, la planificación para el futuro, el establecimiento de objetivos y la evaluación de prioridades.
- Lóbulo parietal: Procesa información sobre temperatura, gusto, tacto y movimiento (percepción de estímulos).
- Lóbulo temporal: Procesa memoria, lenguaje y sonidos.
- Lóbulo occipital: Responsable de la visión y procesamiento visual.

Dado esto, se tiene que las denominaciones de los electrodos se basan en la inicial de cada lóbulo cerebral. Por ejemplo, para el caso de Psicosis vs. Control de Double Flash se tienen 6 características asociadas a los electrodos F que a la vez se encuentran relacionados con el lóbulo frontal, 9 características relacionadas con el lóbulo parietal (nodos P), 3 características asociadas con el lóbulo occipital (nodos O e I), y 4 relacionadas con la región central del cerebro (nodos C), que podría considerarse como la frontera entre los lóbulos frontal y parietal.

Se debe considerar que la aproximación EEG y lóbulo frontal tiene limitaciones, puesto que la actividad eléctrica que se registra en cada electrodo proviene de múltiples fuentes corticales, muchas de ellas lejanas a la zona del electrodo. Esto implica que existe superposición de las señales emitidas por cada lóbulo cerebral en los electrodos, por lo que una característica no se encuentra necesariamente asociada por completo a un determinado electrodo.

Teniendo lo anterior, como la tarea Double Flash consiste en un estímulo audiovisual y la presión de un botón, tiene sentido que una cantidad importante de las características seleccionadas estén asociadas en gran parte al lóbulo parietal debido a la percepción de estímulos mientras que otras estén asociadas al lóbulo frontal debido a los movimientos voluntarios musculares de las manos. Por otro lado, en las figuras de electrodos para Resting

²Brain Anatomy and Limbic System <https://www.brightfocus.org/alzheimers/infographic/brain-anatomy-and-limbic-system>

State se aprecia una distribución más aleatoria debido a que los pacientes no realizaron otra actividad más que mantener los ojos abiertos o cerrados, lo que puede generar movimientos musculares por incomodidad o la percepción de estímulos que no existen (alucinaciones) para el caso de los pacientes con esquizofrenia. Existen características adicionales que no pueden visualizarse aquí debido a que son canales de EOG, con otras distribuciones de electrodos.

En contraste, si se analizan las características seleccionadas según el tipo de extracción (funciones de Entropy/PyEEG) se obtiene lo siguiente, extraído directamente de Python:

```

1 EQZ vs Control RS features 128Hz: ['AF7 RIR_alpha', 'AF3 Power_alpha', 'F1 SVD', 'F7
RIR_alpha', 'T7 Power_alpha', 'CP3 RIR_gamma', 'P07 RIR_delta', 'P03 SVD', 'Oz
Hjorth_complexity', 'P0z RIR_alpha', 'CPz Power_delta', 'Fpz RIR_alpha', 'AF4 RIR_alpha',
'F4 Power_theta', 'F6 Power_theta', 'FCz RIR_theta', 'T8 higushi', 'TP8 RIR_theta', '
CP4 Spectral', 'P6 higushi', 'P8 Power_theta', 'P08 Power_alpha', 'P08 RIR_alpha', 'P04
higushi', 'O2 SVD', 'EXG1 katz', 'EXG3 RIR_alpha', 'EXG8 higushi']
2 EQZ vs Control RS features 256Hz: ['F5 RIR_delta', 'FT7 RIR_theta', 'FC5 RIR_theta', 'FC1
Power_theta', 'C3 RIR_beta', 'T7 RIR_beta', 'CP1 RIR_delta', 'P07 RIR_theta', 'P03
RIR_theta', 'P0z Power_delta', 'Fpz RIR_theta', 'AF8 Power_theta', 'AF4 SVD', 'AFz SVD',
'FT8 Power_theta', 'TP8 RIR_theta', 'O2 RIR_delta', 'EXG3 Power_gamma', 'EXG4 higushi',
'EXG5 Power_theta', 'EXG5 SVD', 'EXG6 Hjorth_mobility', 'EXG7 RIR_gamma']
3 EQZ vs Control DBF features: ['C3 RIR_beta', 'TP7 RIR_beta', 'CP5 RIR_beta', 'P3 DFA', 'P03
RIR_theta', 'O1 RIR_beta', 'O1 DFA', 'Fpz DFA', 'AF4 Power_alpha', 'FC6 RIR_theta', 'FC6
RIR_beta', 'FC4 Power_beta', 'C6 RIR_theta', 'P10 RIR_theta', 'P08 Power_gamma', 'EXG2
Power_gamma', 'EXG5 Power_beta', 'EXG5 Power_gamma']
4 PSI vs Control DBF features: ['AF3 Power_alpha', 'F3 RIR_theta', 'F5 RIR_beta', 'FC5
RIR_beta', 'C1 Power_theta', 'C1 RIR_beta', 'P1 Power_alpha', 'P1 Hjorth_mobility', 'P07
Spectral', 'P03 RIR_theta', 'P03 RIR_alpha', 'O1 RIR_beta', 'Iz Power_gamma', 'Pz
RIR_theta', 'Fpz RIR_alpha', 'FC6 RIR_theta', 'C2 Power_theta', 'C4 Power_gamma', 'P4
Power_beta', 'P10 RIR_theta', 'P08 RIR_theta', 'O2 RIR_theta', 'EXG2 Power_gamma', 'EXG5
Power_beta', 'EXG5 Power_gamma', 'EXG7 Power_delta']

```

El texto anterior se puede convertir en histogramas de palabras para determinar cuáles son las características más relevantes en cada conjunto, incluyendo las bases de datos de 128 Hz y 256 Hz de Resting State y los dos conjuntos de Double Flash en un solo histograma, respectivamente:




Figura 4.36: Histogramas de características, ambos conjuntos.

A partir de estos histogramas, se aprecia que las relaciones de intensidad relativa (RIR) de las bandas de potencias son las características más relevantes tanto para Resting State como Double Flash, seguidas de las intensidades de potencia espectral (Power). Es importante destacar que en ambos conjuntos la característica RIR de la onda Theta es la que tiene mayor frecuencia, lo que implica que es una característica importante para cualquier método de selección de características. También se destaca la inclusión de los canales de electrooculograma (EXG) para la selección de características, puesto que ambas tareas tienen alta actividad y movimiento ocular.

Se nota además que existe mayor actividad en la banda Theta para ambas tareas, donde tiene más sentido asociarla al estado Resting State puesto que se está en un estado de reposo por 2 minutos con ojos abiertos, y 2 minutos con ojos cerrados, siendo esta última la que puede influir en el estado inicial de sueño asociada a las ondas Theta y Alfa. Esto es reforzado por lo expuesto en el artículo *EEG Frequency Bands in Psychiatric Disorders: A Review of Resting State Studies* [33] donde se demuestra que existe un aumento en la potencia de las bandas de baja frecuencia (Delta, Theta) en pacientes con esquizofrenia al realizar la prueba de Resting State, tal como se ve en el histograma, con la diferencia de que en este caso se incluye la actividad en Alfa, que también puede considerarse de baja frecuencia.

Por otro lado, para Double Flash es más lógico asociar esta tarea con la actividad en la banda Beta y Gamma, puesto que presentan mayor actividad en labores de alta concentración. Esto se demuestra en el histograma (b) ya que si se suma la cantidad de características asociadas a la banda Beta junto a Gamma (20) se tiene un número mayor que características asociadas a la banda Theta (13), demostrando la relación entre el grado de actividad cerebral con las bandas de frecuencia. Actualmente se encuentra en estudio la relación de la banda Gamma con la tarea Double Flash por investigadores de la Clínica Psiquiátrica de la Universidad de Chile, por lo que estos resultados sirven de apoyo al estudio.

4.8.2. Conjuntos Sternberg, MVD y MMN Emocional

Los casos que obtuvieron sobre 80% de precisión promedio en estos conjuntos corresponden solamente a problemas binarios de clasificación de APS, que corresponde a un nivel de psicosis leve, por lo que no se tendría una relación tan fuerte con los lóbulos del cerebro comparado por los conjuntos anteriores donde predominaba la esquizofrenia y FEP. Dado esto, excepcionalmente se incluirá el resultado de clasificación de FEP obtenido para la tarea Sternberg, con las siguientes características seleccionadas y sus respectivos histogramas:

-
- 1 FEP vs CNIF STB features: ['Fp1 RIR_alpha', 'FT7 RIR_theta', 'FC5 RIR_gamma', 'TP7 katz', 'TP7 DFA', 'P5 RIR_beta', 'P9 Hjorth_complexity', 'FC2 RIR_theta', 'T8 RIR_beta', 'CP6 Spectral', 'CP4 Perm', 'P08 RIR_beta']
 - 2 APS vs CNIA STB features: ['Fp1 Power_delta', 'Fp1 katz', 'AF7 Power_theta', 'P7 Power_delta', 'Oz katz', 'Fpz katz', 'F4 RIR_delta', 'CP2 RIR_theta', 'P04 RIR_delta', 'EXG6 RIR_beta', 'EXG7 RIR_theta']
 - 3 PSI vs Control MVD features: ['F3 RIR_beta', 'FC3 DFA', 'C5 Perm', 'P03 DFA', 'P0z RIR_delta', 'Fp2 Power_delta', 'Fp2 Power_gamma', 'P2 Power_beta', 'EXG3 Power_beta', 'EXG3 Power_gamma', 'EXG8 Power_theta', 'EXG8 RIR_beta', 'EXG8 RIR_gamma']
 - 4 APS vs Control MMN features: ['Fp1 Power_gamma', 'Fp1 RIR_alpha', 'F1 Power_theta', 'F3 DFA', 'CPz katz', 'Fp2 katz', 'Fp2 DFA', 'AFz Power_theta', 'F2 RIR_beta', 'F4 RIR_beta', 'Cz DFA', 'P8 Power_theta']
-





Figura 4.37: Histogramas de características para STB, MVD, MMN y total.

Analizando las frecuencias de características en los histogramas, las que más se repiten para los 3 conjuntos por igual son la razón de intensidad relativa (RIR) de la onda Beta, dimensión fractal Katz y análisis de fluctuación de tendencia. En cambio, analizando cada conjunto por separado se tiene que para Sternberg existe una mayor cantidad de características relacionadas con la razón de intensidad relativa de las ondas Delta, Theta, Gamma, Alfa y Beta, mientras que para Moving Dots predomina la intensidad de potencia espectral (IPE) por sobre RIR, y para MMN existe un balance entre IPE y RIR puesto que tienen igual cantidad de características seleccionadas.


En los histogramas se aprecia que la mayor actividad se concentra la banda de frecuencia Beta (12-30 Hz) que está asociada a momentos de pensamiento intenso o ansioso y concentración activa, los que se pueden asociar al nivel de concentración presente en las pruebas Sternberg (memoria) y Moving Dots (movimiento biológico), mientras que para MMN Emocional no existe una banda de frecuencia que predomine mayormente por sobre las otras, ya que MMN es una actividad más pasiva que las otras tareas.

Como análisis de todos los histogramas para las 5 tareas, se tiene que las características más relevantes son las de **intensidad de potencia espectral** y **razón de intensidad relativa** de las bandas de frecuencias de EEG, siendo estas características las que permiten la obtención de mejores resultados de clasificación al definir de mejor forma las muestras de las bases de datos. Ahora bien, la única característica que no aparece en los histogramas es la información de Fisher, mientras que las menos relevantes son la entropía espectral y los parámetros de Hjorth, por lo que estas características se podrían eliminar sin afectar en gran medida los rendimientos de los sistemas de clasificación.


Desde el punto de vista clínico, las características seleccionadas se encuentran espacialmente ubicadas en las siguientes distribuciones de electrodos:




((a)) FEP vs CNTF, Sternberg



((b)) APS vs CNTA, Sternberg



((c)) Psicosis vs Control, Moving Dots



((d)) APS vs Control, MMN Emocional

Figura 4.38: Asociación de características a distribución de electrodos, STB, MVD y MMN.

Para las figuras 4.38a y 4.38b, se tienen 9 características asociadas al lóbulo frontal, 8 al

parietal, 3 al temporal y 1 al occipital (3 si se considera PO como parietal-occipital). Cabe recordar que la prueba Sternberg consiste en la presentación de letras de manera sucesiva, y apretar un botón si es que la última letra se encontraba en la serie. Dado que esta actividad requiere de una alta concentración y movimiento voluntario, tiene sentido que las características estén mayormente relacionadas al lóbulo frontal, mientras que se asocian al parietal por los cambios sucesivos de las letras, relacionado con el movimiento. Los lóbulos temporales se asocian a tener que memorizar si la letra se encontraba en la serie mientras que la actividad en el lóbulo occipital se debe en menor medida a la variación visual de las letras en pantalla.

Para la tarea Moving Dots, se tienen puntos blancos que se mueven en el espacio por lo que habría una mayor actividad en los electrodos del electrooculograma (EXGs), y los lóbulos parietales-occipitales. En tanto, se tienen 5 características asociadas a EXG, 4 a lóbulo frontal, 2 a electrodos PO (parietal-occipital), 1 al lóbulo parietal y 1 en la zona central, donde se demuestra que hay mayor relación a electrodos asociados a la visión y movimiento. Las características asociadas al lóbulo frontal pueden deberse a que la variación del movimiento sincronizado genera cambios de ánimos en los pacientes con psicosis.

Por último, se tiene la prueba MMN Emocional asociada a estímulos auditivos y estados emocionales, por lo que debería predominar la actividad en el lóbulo temporal y frontal, donde finalmente se tiene una mayoría de características asociadas a electrodos en el lóbulo frontal, lo que tiene sentido teóricamente. Sin embargo, no existen características asociadas al lóbulo temporal, siendo que en esta actividad predominan los sonidos.

Conclusiones y discusión

En este trabajo se desarrolló con buenos resultados un sistema de clasificación de psicosis, utilizando procesamiento digital de series de tiempo aplicado a señales de electroencefalograma para su filtrado y extracción de características y herramientas de aprendizaje de máquinas para su clasificación. Se utilizaron las 5 tareas psicológicas disponibles, de las cuales Resting State y Double Flash son las más accesibles y de menor tiempo de procesamiento por tener menor cantidad de información, o menor tamaño en bytes, que las otras 3 bases de datos.

Del conjunto Resting State, se logró un análisis comparativo de metodologías de procesamiento de señales obteniendo como la mejor metodología utilizar el filtrado pasabanda de fase cero *filtfilt*, en lugar de *eegfilt*, entre las frecuencias 0.5 y 60 Hz para cubrir todo el espectro de las EEG, luego usar los algoritmos de eliminación de artefactos ICA y *Adjust*, y finalmente reducir la frecuencia de la señal a 256 Hz. En cuanto a este último punto también se discute el submuestreo a 256 Hz o 128 Hz, donde se demuestra que al tener mayor frecuencia de muestreo se obtienen mejores resultados puesto que al tener mayor cantidad de datos se pueden caracterizar de mejor forma las señales, pero como se señala en los resultados esta variación es muy leve, siendo a veces prácticamente imperceptible. Además, al comparar las funciones de extracción de características se concluye que utilizar las librerías PyEEG y Entropy en conjunto entrega mejores resultados que utilizar solo las funciones de PyEEG, entregando una precisión promedio máxima para el conjunto de 256 Hz de 78.7% y desviación estándar de 8.41, que es bastante bueno para este problema.

Luego se estudia el efecto de dividir las señales en dos, ojos abiertos y ojos cerrados, duplicando la cantidad de características del sistema. Puesto que son dos señales de actividades diferentes, se pensó que generarían mejores resultados de precisión, obteniendo lo contrario ya que la sensibilidad promedio de los conjuntos disminuyó considerablemente por lo que esta metodología no es recomendable.

También se realiza un análisis al seleccionar canales de las señales mediante entropía aproximada con y sin los canales EOG de las señales en general, tanto para el conjunto de 128 Hz como 256 Hz. Se pudo apreciar que no existe una variación importante en las precisiones promedio al disminuir los canales, obteniendo precisiones mayores a 75% al utilizar solo 18 canales. Por otro lado, la especificidad promedio prácticamente no se ve afectada en ningún caso de selección de canales, manteniéndose sobre 85% para el clasificador SVM.

Luego se realizan experimentos usando conjuntos con características seleccionadas por el programa WEKA, donde existen incrementos sustanciales en los valores de precisión y sensibilidad promedio, por lo que seguir esta metodología de selección es fundamental para mejorar

los resultados de clasificación y optimizar el sistema. Por lo demás, se tiene que el problema de clasificación que mejor resuelve Resting State es el problema binario de clasificación de esquizofrenia, con precisión promedio sobre el 80 %, seguido del problema binario de clasificación de APS vs. Control adolescente, con 78.31 % de precisión promedio, pero muy bajo valor de especificidad. A partir de esto se concluye que el conjunto Resting State es el óptimo para clasificar esquizofrenia, pero no otros tipos de psicosis.

En contraste, la clasificación de esquizofrenia utilizando el conjunto Double Flash inicialmente obtuvo resultados inferiores a Resting State, pero luego de aplicar selección de características aumentó considerablemente los valores de precisión, sensibilidad y especificidad promedio llegando a 87.1 %, 84.45 % y 89.2 % para el clasificador SVM, respectivamente. Luego se realiza la clasificación de psicosis, logrando aún mejores resultados: 88.78 %, 91.08 % y 84.64 % respectivamente, y reduciendo la dispersión de los datos. Se concluye que la tarea Double Flash puede diferenciar, y por ende clasificar, de mejor forma tanto psicosis en general como esquizofrenia a los grupos de control que el conjunto Resting State.

También se realizaron pruebas con los conjuntos Sternberg, Moving Dots y MMN Emocional, los cuales tenían muestras de mayor tamaño computacional que Resting State y Double Flash, pero no tenían muestras etiquetadas como esquizofrenia. Del conjunto Sternberg se obtuvo valores de precisión promedio máxima de 75.65 % para la clasificación de FEP vs. Control adulto, con 72.98 % de sensibilidad y 79.15 % de especificidad y valores de desviación estándar moderadamente altos de 14.62 y 16.45, respectivamente, mientras que la clasificación de APS vs Control adolescente resultó en porcentajes promedios máximos de 90.54 %, 89.29 % y 93.01 % de precisión, sensibilidad y especificidad, respectivamente, con valores de desviación estándar inferiores, porcentajes conseguidos por el clasificador LDA. Para Moving Dots, los mejores valores promedio de precisión, sensibilidad y especificidad obtenidos por LDA son de 85.39 %, 89.44 % y 82.02 %, respectivamente con desviación estándar relativamente baja para el problema de clasificación Psicosis vs Control, notando que solo existía una muestra FEP y el resto correspondía a APS. Por último, para el conjunto MMN Emocional se obtuvieron valores promedio máximos usando Gradient Boosting de 86.72 %, 74.47 % y 92.82 % para precisión, sensibilidad y especificidad, respectivamente, para el problema de clasificación APS vs Control. De estos resultados se concluye que estas bases de datos son útiles para diferenciar pacientes con síndrome de psicosis atenuada (APS) de los del grupo de control, pero no son suficientes para resolver el problema de clasificación general de psicosis o esquizofrenia, puesto que no tienen suficientes datos como MMN y MVD, o las muestras FEP no tienen diferenciación suficiente con las otras muestras como ocurre en STB. A pesar de esto, se destaca que la precisión promedio más alta alcanzada por las 5 bases de datos es de 90.54 %, usando la tarea Sternberg y clasificador Linear Discriminant Analysis.

Comparando estos resultados con los de la literatura, son bastante notables puesto que se obtienen resultados de precisión, en promedio, cercanos a 90 % para Double Flash y 85 % para Resting State. Por lo demás, la metodología planteada aquí es única ya que estos resultados se obtuvieron sin realizar división en ventanas de tiempo o traslapes a las señales, utilizando toda la señal tanto en tiempo como en frecuencia, además de utilizar técnicas más convencionales de análisis de series de tiempo. También, de los artículos expuestos ninguno presenta algoritmos de selección de características usando métodos de fácil implementación como WEKA, ya que este programa demostró que se estaban utilizando características que

no aportaban información al sistema y podrían haber generado sobreajuste, también conocido como *overfitting*, al entrenar los clasificadores sin selección de características. Puesto que se utilizó la validación cruzada de Monte Carlo, junto a selección de características y elección automática de parámetros de los clasificadores se demuestra que el sistema es robusto ante el sobreajuste de datos. Además, el mejor clasificador de este trabajo en general es Support Vector Machine, cuando en la literatura se utilizan mayoritariamente árboles de decisión o redes neuronales convolucionales o recurrentes. Por último, se debe destacar que en este trabajo no solo se logró clasificación de esquizofrenia como en la mayoría de los artículos, sino que también clasificación de psicosis en general, dado por los buenos resultados de la tarea Double Flash. En menor medida se tienen los resultados de clasificación de APS usando la Sternberg, que a pesar de que son buenos e incluso mejores que Double Flash, su aplicación es más acotado puesto que no clasifica psicosis en general correctamente.

Los experimentos realizados en este trabajo son un aporte útil a la medicina moderna y la clínica psiquiátrica en especial, ya que al tener buenos resultados de clasificación de esquizofrenia y APS se tienen indicadores objetivos para la diferenciación de pacientes con psicosis y pacientes sanos, y adicionando el hecho de que es un sistema altamente automatizado, se puede utilizar de apoyo para el diagnóstico de psicosis por parte de psicólogos y psiquiatras. Por lo demás, dada la forma en que se constituyó el sistema de clasificación, es posible entrenar los algoritmos con bases de datos EEG de otros trastornos mentales, como Alzheimer, depresión, psicopatía, etc. siguiendo las mismas metodologías de extracción de características y clasificación, lo que implica que el trabajo expuesto sirve para el análisis de trastornos de salud mental de forma generalizada, tomando en consideración la posibilidad modificar levemente los algoritmos de procesamiento de señales y de extracción de características, según se requiera.

Las limitaciones de este trabajo se consideran más técnicas, como por ejemplo que las funciones de procesamiento de Matlab tienen problemas para procesar señales de un tamaño mayor a 1 Gigabyte debido a las limitaciones de memoria RAM que puede utilizar Matlab en un determinado momento. También, hay que considerar que la selección de características varía según la base de datos a utilizar, por lo que para clasificar una nueva muestra no etiquetada será necesario seguir los mismos pasos para obtener las señales EEG, que en este caso son las tareas Resting State, Double Flash, Sternberg, Moving Dots y MMN Emocional de la clínica psiquiátrica de la Universidad de Chile y el casco de 72 electrodos. Dado esto, como trabajo propuesto a futuro se deben considerar utilizar otros tipos de tareas cognitivas no expuestas aquí, con algoritmos de procesamiento de señales optimizados para obtener resultados de clasificación distintos, que podrían ser peores o mejores a los expuestos por este trabajo junto con utilizar otros tipos de extracción de características, ya sea análisis de series de tiempo o de ERP.

Bibliografía

- [1] National Institute of Mental Health. <https://www.nimh.nih.gov/health/topics/schizophrenia/raise/raise-questions-and-answers.shtml#1>. Accessed: 17-06-2019.
- [2] WebMD, Psychotic Disorders. <https://www.webmd.com/schizophrenia/guide/mental-health-psychotic-disorders#2-6>. Accessed: 17-06-2019.
- [3] Wieselgren I.M. Vonknorring L Lindstrom, E. *Interrater reliability of the structured clinical interview for the positive and negative syndrome scale for schizophrenia*. Acta Psychiatr Scand, 1994.
- [4] Neuromarketing Science & Business Association (with references). *Signal to Noise Ratio in EEG*, (Accessed November 20, 2020). <https://www.nmsba.com/buying-neuromarketing/neuromarketing-techniques/signal-to-noise-in-eeeg>.
- [5] F. Lotte, J. Casteta, and E. Reck Miranda. *A Tutorial on EEG Signal Processing Techniques for Mental State Recognition in Brain-Computer Interfaces*. Guide to Brain-Computer Music Interfacing, Springer, 2014.
- [6] What is the purpose of Theta brain waves? <https://www.healthline.com/health/theta-waves>. Accessed: 21-03-2021.
- [7] Nitish V. Thakor and David L. Sherman. EEG Signal Processing: Theory and Applications. In Bin He, editor, *Neural Engineering, Second Edition*, chapter 5, pages 260–262. Springer, Minneapolis, 2013.
- [8] C.H. Vanderwolf. Are neocortical gamma waves related to consciousness? *Brain Res.*, 855:217–224, 2000.
- [9] Katebi S.D. Boostani R. Price G.W. Sabeti, M. A new approach for EEG signal classification of schizophrenic and control participants. *Expert Systems with Applications*, 38:2–3, 2012.
- [10] R Quian Quiroga, S Blanco, OA Rosso, H Garcia, and A Rabinowicz. Searching for hidden information with gabor transform in generalized tonic-clonic seizures. *Electroencephalography and clinical Neurophysiology*, 103(4):434–439, 1997.
- [11] A. Petrosian. Kolmogorov complexity of finite sequences and recognition of different

preictal eeg patterns. pages 212–217, June 1995.

- [12] T. Higuchi. Approach to an irregular time series on the basis of the fractal theory. *Phys. D*, 31(2):277–283, June 1988.
- [13] R. Esteller, G. Vachtsevanos, J. Echauz, and B. Litt. A comparison of waveform fractal dimension algorithms. *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications*, 48(2):177–183, Feb 2001.
- [14] Bo Hjorth. Eeg analysis based on time domain properties. *Electroencephalography and clinical neurophysiology*, 29(3):306–310, 1970.
- [15] Tsuyoshi Inouye, Kazuhiro Shinosaki, H Sakamoto, Seigo Toi, Satoshi Ukai, Akinori Iyama, Y Katsuda, and M Hirano. Quantification of eeg irregularity by use of the entropy of the power spectrum. *Electroencephalography and clinical neurophysiology*, 79(3):204–210, 1991.
- [16] Christoph Bandt and Bernd Pompe. Permutation entropy: A natural complexity measure for time series. *Physical review letters*, 88:174102, 05 2002.
- [17] Stephen J Roberts, William Penny, and Iead Rezek. Temporal and spatial complexity measures for electroencephalogram based brain-computer interfacing. *Medical & biological engineering & computing*, 37(1):93–98, 1999.
- [18] Christopher J James and David Lowe. Extracting multisource brain activity from a single electromagnetic channel. *Artificial Intelligence in Medicine*, 28(1):89–104, 2003.
- [19] C-K Peng, Shlomo Havlin, H Eugene Stanley, and Ary L Goldberger. Quantification of scaling exponents and crossover phenomena in nonstationary heartbeat time series. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 5(1):82–87, 1995.
- [20] Steven M Pincus, Igor M Gladstone, and Richard A Ehrenkranz. A regularity statistic for medical data analysis. *Journal of clinical monitoring*, 7(4):335–345, 1991.
- [21] Kalon K. L. Ho, George B. Moody, C K Peng, Joseph E. Mietus, Martin G. Larson, Daniel Lévy, and Ary L. Goldberger. Predicting survival in heart failure case and control subjects by use of fully automated methods for deriving nonlinear and conventional indices of heart rate dynamics. *Circulation*, 96 3:842–8, 1997.
- [22] Alexander Craik, Yongtian He, and Jose L Contreras-Vidal. Deep learning for electroencephalogram (EEG) classification tasks: a review. *Journal of Neural Engineering*, 16:031001, 2019.
- [23] Christ Devia, Rocío Mayol Troncoso, Javiera Parrini, Gricel Orellana, Aida Ruiz A, Pedro Maldonado, and Josi Ignacio Egana. EEG Classification During Scene Free-Viewing for Schizophrenia Detection. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, PP:1–1, 04 2019.
- [24] Werner Dubitzky, Martin Granzow, and Daniel P. Berrar. *Fundamentals of Data Mining*

in Genomics and Proteomics. Springer-Verlag, Berlin, Heidelberg, 2006.

- [25] Max Kuhn and Kjell Johnson. *Applied predictive modeling*. Springer, New York, NY, 2013.
- [26] Decomposing data using ICA. https://sccn.ucsd.edu/wiki/Chapter_09:_Decomposing_Data_Using_ICA#Independent_Component_Analysis_of_EEG_data. Accessed: 13-12-2019.
- [27] Jovicich-J. Bruzzone L. Buiatti M. Mogron, A. ADJUST: An Automatic EEG artifact Detector based on the Joint Use of Spatial and Temporal features. *Psychophysiology*, 48:229–240, 2011.
- [28] L. Zhang. EEG Signals Classification Using Machine Learning for The Identification and Diagnosis of Schizophrenia. In *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 4521–4524, 2019.
- [29] Ricardo Buettner, David Beil, Stefanie Scholtz, and Aadel Djemai. Development of a Machine Learning Based Algorithm To Accurately Detect Schizophrenia based on One-minute EEG Recordings. 01 2020.
- [30] Jason Johannesen, Jinbo Bi, Ruhua Jiang, Joshua Kenney, and Chi-Ming Chen. Machine learning identification of eeg features predicting working memory performance in schizophrenia and healthy adults. *Neuropsychiatric Electrophysiology*, 2, 12 2016.
- [31] Reza Boostani, Khadijeh Sadatnezhad, and Malihe Sabeti. An efficient classifier to diagnose of schizophrenia based on the eeg signals. *Expert Systems with Applications*, 36(3, Part 2):6492 – 6499, 2009.
- [32] Miseon Shim, Han-Jeong Hwang, Do-Won Kim, Seung-Hwan Lee, and Chang-Hwan Im. Machine-learning-based diagnosis of schizophrenia using combined sensor-level and source-level eeg features. *Schizophrenia Research*, 176(2):314 – 319, 2016.
- [33] Jennifer J. Newson and Tara C. Thiagarajan. Eeg frequency bands in psychiatric disorders: A review of resting state studies. *Frontiers in Human Neuroscience*, 12:521, 2019.