

**DETECCIÓN DE INTENCIÓN MOTORA EMPLEANDO TÉCNICAS DE APRENDIZAJE
AUTOMÁTICO**

JUAN SEBASTIÁN RAMÍREZ ARCHILA

Trabajo Dirigido

**Tutor
Álvaro David Orjuela Cañón**



**UNIVERSIDAD DEL ROSARIO
ESCUELA COLOMBIANA DE INGENIERÍA JULIO GARAVITO
PROGRAMA DE INGENIERÍA BIOMÉDICA
BOGOTÁ D.C
2020**

AGRADECIMIENTOS

En primer lugar, quiero agradecer a mis padres ya que son parte fundamental de mi crecimiento y desarrollo personal y profesional. A su constante esfuerzo a lo largo de los años para brindarme la mejor educación, y a su apoyo y amor incondicional que me permiten presentar el actual documento de grado. De igual manera, le agradezco al ingeniero Álvaro Orjuela por su constante apoyo y disposición a la hora de realizar el actual proyecto. Finalmente, también quiero expresar mi gratitud hacia la Universidad del Rosario y a la Escuela Colombiana De Ingeniería Julio Garavito por permitirme forjar los conocimientos necesarios para la realización del proyecto.

TABLA DE CONTENIDO

1. INTRODUCCIÓN.....	4
1.1. Marco Teórico	9
1.1.1. Electroencefalografía	9
1.1.2. Tipos de Registro en el EEG	10
1.1.3. Tipos de Onda en el EEG	11
1.1.4. Corteza Motora	12
1.1.5. Sistema internacional 10 - 20	13
1.1.6. Ritmos Sensoriomotores	14
1.1.7. Aprendizaje Automático	15
2. OBJETIVOS	25
2.1. General	25
2.2. Específico	25
3. METODOLOGÍA.....	26
3.1. Base de Datos	26
3.2. Extracción de Características	28
3.3. Modelos de Aprendizaje Automático	30
4. RESULTADOS	33
5. DISCUSIÓN.....	37
6. RECOMENDACIONES Y TRABAJOS FUTUROS.....	41
7. CONCLUSIONES	42
REFERENCIAS	43
ANEXOS.....	46

1. INTRODUCCIÓN

Según la Organización Mundial de la Salud, alrededor de 250.000 y 500.000 nuevas personas en el mundo sufren alguna lesión de médula espinal cada año [1]. Se desconocen los datos estadísticos para toda Colombia, sin embargo, existen asociaciones nacionales en diferentes países que realizan seguimientos y estudios a personas en esta condición.

En Estados Unidos, el Centro de Estadística Nacional de Lesión de Médula Espinal, estima que 17.810 casos son registrados anualmente, de los cuales, la mayoría corresponden a una lesión medular que resulta en la ausencia de función motora y sensitiva de las extremidades [2].

Existen diferentes tipos de discapacidad por lesión medular, los cuales son clasificados por medio de la escala ASIA (*American Spinal Cord Injury Association*) (ver Tabla 1).

Grado de lesión	Características
A	Lesión Completa: ausencia de función motora y sensitiva por debajo del nivel de la lesión.
B	Lesión Incompleta: ausencia de la función motora, pero se conserva la sensibilidad por debajo del nivel neurológico. Tipo 1. Se conserva el tacto superficial. Tipo 2. Además del tacto superficial, se conserva el dolor y la temperatura.
C	Lesión incompleta: se conserva la sensibilidad y la función motora con fuerza muscular menor de 3 por debajo del nivel neurológico.
D	Lesión incompleta: se conserva la sensibilidad y la función motora con fuerza muscular mayor de 3 por debajo del nivel neurológico
E	Función motora y sensitiva normal.

Tabla 1. Escala ASIA para la clasificación de lesiones medulares.

El grado de lesión más común es el tipo A, ya que se estima que alrededor del 45% de los casos pertenecen a este grupo, mientras que las lesiones de tipo B, C, y D tienen una incidencia del 30%, 15% y 10%, respectivamente [3].

Las secuelas de una lesión en los segmentos cervicales de la médula espinal (C4-C8) pueden afectar a órganos pélvicos, extremidades inferiores, tronco, abdomen, y extremidades superiores. Cuando la lesión se presenta superior a C4, se le denomina tetraplejía dependiente de ventilación mecánica, y cuándo se presenta por debajo de la ubicación de C4, se le denomina tetraplejía o cuadriplejía [4].

Se le conoce como cuadriplejía o tetraplejía a la pérdida de la función motora o sensitiva de los miembros inferiores y superiores. Este signo clínico suele definirse en dos grupos: tetraplejía completa, y tetraplejía incompleta [5]

Las personas que presentan lesión medular completa tienen menos del 10% de probabilidad de mejorar su escala funcional, y las secuelas que presentan pueden ir desde pérdida de la sensibilidad, paresia, hasta parálisis total [6].

A raíz de la movilidad limitada o nula que se presenta en esta condición, es necesario modificar dispositivos esenciales de la vida cotidiana que permitan a estas personas realizar acciones con la mayor normalidad posible, permitiendo así mejorar su calidad de vida.

Una característica determinante en el desarrollo, y autonomía como seres humanos es la movilidad, la cual se define como la capacidad de moverse de forma independiente de un lugar a otro [7].

La recuperación de la independencia para movilizarse es el objetivo principal de los procesos de rehabilitación para personas que presentan tetraplejía, a pesar de que poseen solo un 10% de probabilidad de mejora en su escala funcional.

Desde el campo de la ingeniería biomédica se ofrecen diferentes alternativas para mejorar sustancialmente la calidad de vida de las personas. Dichas alternativas pueden involucrar diversas áreas como la biomecánica, la bioinstrumentación, el aprendizaje automático aplicado en salud, entre otras. Estas soluciones van desde dispositivos de entretenimiento como juguetes, juegos controlados por gestos, movimientos leves, sentimientos, potenciales evocados, etc... hasta el diseño de prótesis, órtesis, y diversos dispositivos de asistencia controlados digitalmente por señales bioeléctricas.

Una alternativa de alta innovación para la movilidad de estas personas, son sillas de ruedas controladas a través de la lengua [8], sin embargo, esta solución puede conllevar incomodidad y dolor al paciente al tener que realizar contracciones y relajaciones de los músculos linguales de manera continuada.



Figura 1. Silla de ruedas controlada por la lengua. [9]

Otra opción de movilidad para personas con tetraplejía, son sillas de ruedas controladas por medio de un joystick [10]. Sin embargo, estas presentan una gran limitación frente a las personas que sufren tetraplejía completa, ya que le es imposible manipular el joystick debido a la movilidad nula o limitada que poseen.

Una manera de mejorar la calidad de vida de una persona en condición de tetraplejía es devolviéndole la capacidad de movilizarse de manera independiente. En este contexto, existen diversas soluciones enfocadas en desarrollar este propósito. Existen prótesis de miembros superiores e inferiores las cuales se manipulan a placer debido al registro continuo de señales de electroencefalografía (EEG) y electromiografía (EMG), proporcionando información suficiente para clasificar diferentes tipos de movimiento, o intenciones de movimiento. La clasificación realizada permite inducir diferentes movimientos de las partes mecánicas de las prótesis, generando un movimiento característico y permitiéndole al usuario manipularlas y controlarlas [11].

El mismo principio es usado para desarrollar vehículos de asistencia para personas en condición de tetraplejía, en el cual, a través de movimientos leves, pensamientos, o ambos, pueden controlar el vehículo y desplazarse de un lugar a otro.

Un método comúnmente empleado para clasificar movimientos o intenciones de movimiento es por medio del análisis de señales de EEG, haciendo uso de algoritmos de clasificación automática. Estos análisis son realizados por medio de la extracción de características temporales y frecuenciales, las cuales son sometidas a técnicas de análisis de datos que buscan generalizar comportamientos o inferencias, respecto a características de referencia que son previamente extraídas [12]. En el momento en el que las señales son clasificadas, y el sujeto sobre el cual se realiza la lectura es realimentado sensorialmente, se habla de un sistema de interfaz cerebro máquina.

Una interfaz cerebro máquina (*BCI por sus siglas en inglés*), es un dispositivo que permite la interacción del ser humano con diversos dispositivos electrónicos. Las funcionalidades de una BCI van desde transmitir información sensorial, hasta el control de exoesqueletos y la restauración de funciones sensoriales [12].

Los sistemas BCI fueron propuestos por primera vez por Jacques Vidal en 1973, cuándo demostró que las señales obtenidas producto de la actividad cerebral podían ser usadas para predecir la intención de una persona [13]. Desde entonces, las propuestas de BCI han variado y se han fortalecido dependiendo de la aplicación. Estrategias como los potenciales evocados (VEP, por su sigla en inglés *Visual Evoked Potentials*), potenciales P300, o el análisis de funciones sensorimotoras son empleadas para realizar las clasificaciones de los diferentes movimientos [14]. El diagrama de la Figura 2 muestra las partes fundamentales de la mayoría de las estrategias en BCI.

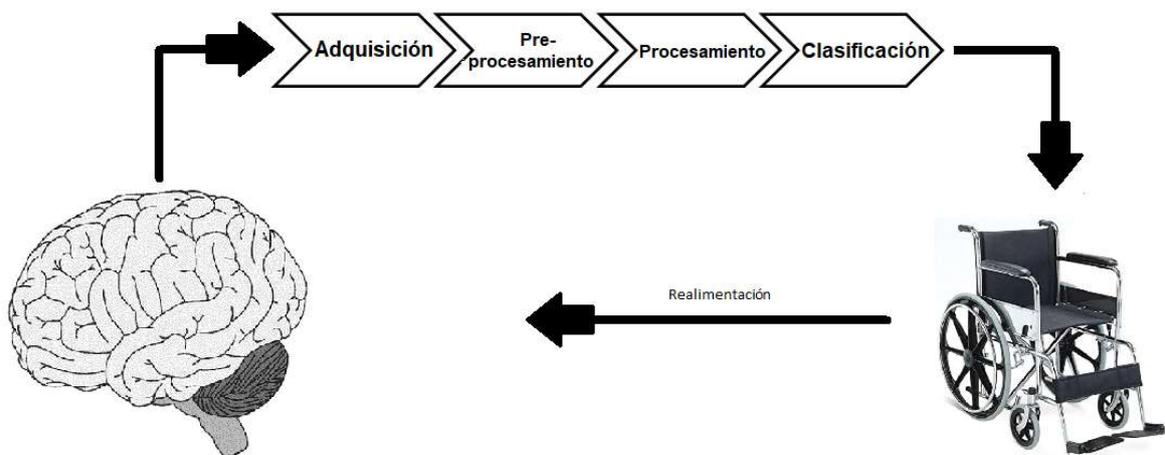


Figura 2. Modelo BCI clásico. Autoría propia.

Actualmente, existen varios estudios en los que emplear técnicas de aprendizaje automático para detectar la intencionalidad de movimiento, ha sido fundamental para la clasificación de dichos eventos. Incluso, existen algoritmos que presentan exactitudes por encima del 75% [12] [4] [15].

Los diferentes métodos empleados para detectar la intención de movimiento en señales de EEG involucran diferentes parámetros como lo pueden ser el número de electrodos empleados, las técnicas de pre-procesamiento de las señales, las características extraídas para la etapa de clasificación, la selección de características, los algoritmos de aprendizaje automático empleados, las técnicas de validación, entre otras. Esto puede conllevar a numerosas alternativas que los investigadores pueden tener a la hora de realizar estudios relacionados con la detección de intención de movimiento. De acuerdo con lo anterior, puede ser común encontrar diferentes artículos científicos con propósitos similares a los de este proyecto, dónde son analizados Potenciales Relacionados a Eventos (ERP), debido a la fácil detección motora que otorga, sin embargo, las etapas de procesamiento que se emplean son demasiado robustas [16].

En relación con la etapa de clasificación en los sistemas BCI es común hacer uso de los diferentes algoritmos de aprendizaje automático existentes, los cuales, a partir de un grupo de características extraídas de señales cerebrales, buscan clasificar nuevas muestras desconocidas de nuevas señales, comparándolas con las características de las muestras ya clasificadas [17].

Uno de los métodos más comunes para clasificar la imaginación motora es el uso de Máquinas de Soporte Vectorial (*SVM por sus siglas en inglés*), como en el estudio de (Pulido & López, 2017) [12], en el cual se busca clasificar la imaginación motora de miembro superior (agarrando un objeto), y la relajación. Para dicha extracción, fueron empleadas características temporales y frecuenciales, las cuales permitieron alcanzar una exactitud de 81.72%. Se resalta, que en dicho estudio notaron que la relación de las potencias relativas de alfa y beta puede fallar, debido a que un incremento en la atención del sujeto puede provocar errores en la clasificación.

En el estudio de (Triana, Orjuela-Cañón, & Jutinico, 2019) [18] fueron empleados únicamente las frecuencias relativas de alfa y beta para detectar la imaginación motora, diferenciando movimiento de puño derecho, movimiento de puño izquierdo, y descanso. La técnica de aprendizaje automático empleada fue la del Perceptrón Multicapa (MLP) con *back-propagation*, obteniendo resultados cercanos al 75%. Es importante aclarar que el estudio mencionado empleó también la misma base de datos que la de este proyecto, sin embargo, únicamente utilizaron la información de un sujeto para realizar el algoritmo de clasificación.

En diferentes estudios como en el de (Mdisa, Amir, Ilyas, & Razalli, 2017) y Khan, Bhatti, Khan, & Iqbal, 2019 [19] [20] se emplearon algoritmos de clasificación por agrupación, como el de K-vecinos más cercanos (kNN) para detectar intención de movimiento. Obtuvieron exactitudes cercanas al 81.66% utilizando como criterio de medición la distancia de Minkowski para clasificar las nuevas muestras, teniendo en cuenta los 11 vecinos más cercanos.

Los árboles de decisión también han sido usados como método de clasificación para la detección de imaginación motora, obteniendo exactitudes hasta del 94% [21], y como es común, se utilizaron características frecuenciales para determinar las nuevas clases de las nuevas muestras, las cuales eran movimiento imaginario del puño derecho, movimiento imaginario de puño izquierdo, y movimiento imaginario de pies. En trabajos como el de (Khan, Bhatti, Khan, & Iqbal, 2019) [20] se evalúan diferentes técnicas de clasificación, las cuales incluyen árboles de decisión, máquinas de soporte vectorial (SVM), y técnicas de agrupación por *clustering* como Knn.

El presente trabajo presenta una propuesta para la identificación de imaginación motora en miembro superior de sujetos sanos a partir del procesado de señales electroencefalográficas y técnicas de aprendizaje automático. Además, busca determinar con qué tipo de características se realiza una mejor detección, si con las que son extraídas en el dominio del tiempo, o aquellas que se extraen en el dominio de la frecuencia.

1.1. MARCO TEÓRICO

Para comprender como funciona un sistema BCI es importante tener claros diferentes conceptos relacionados con las todas etapas previamente mencionadas que componen a una interfaz cerebro computadora. Desde la adquisición y generación de los datos, hasta la realimentación sensorial que recibe el sujeto.

1.1.1. ELECTROENCEFALOGRAFÍA (EEG)

La electroencefalografía es una técnica de exploración funcional neurológica basada en el registro de la actividad eléctrica cerebral en tiempo real, desarrollada por primera vez en 1929 por Hans Berger.

La señal se origina en las células piramidales ubicadas en la corteza cerebral, ya que cada neurona constituye un dipolo eléctrico diminuto, cuya polaridad depende de que el impulso hacia la célula sea de tipo inhibitorio o excitatorio. La EEG realiza el estudio y análisis de los campos eléctricos cerebrales mediante la medición y amplificación de la diferencia de potencial entre dos electrodos ubicados a través de la superficie craneal, los cuales son receptores de la señal [22].

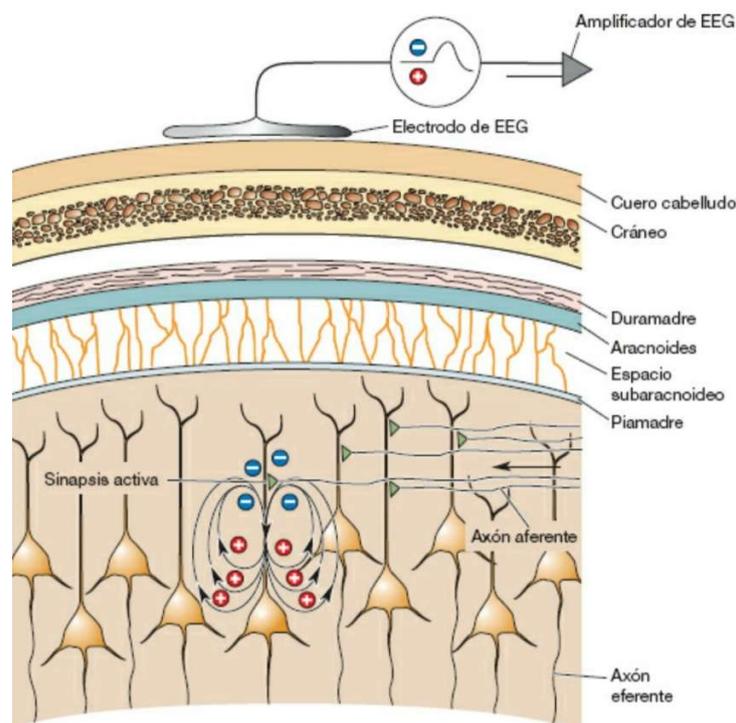


Figura 3. Generación de dipolo eléctrico, y ubicación de un electrodo subcutáneo [23].

Existen diferentes tipos de EEG, dependiendo de la ubicación de los electrodos al momento de realizar la adquisición: EEG estándar (electrodos situados en el cuero

cabelludo), EEG cortical (electrodos situados en la superficie cortical, y EEG de profundidad (electrodos ubicados intracranealmente).

De igual manera, para realizar la captura de las señales neuroeléctricas existen diferentes técnicas, sin embargo, las más usadas son el EEG y el Electroencefalograma (EECoG). Sin embargo, el EECoG presenta una desventaja muy grande respecto al EEG, y es que es necesaria una intervención quirúrgica con el fin de posicionar los electrodos bien sea de forma cortical o intracerebral [24].

1.1.2. TIPOS DE REGISTRO DE EEG

Existen dos tipos de montaje para realizar el registro de las ondas electroencefalográficas, sin embargo, en ambos casos es necesario ubicar varios electrodos sobre el cuero cabelludo, permitiendo al terminal captar la diferencia de potencial presentada entre dos puntos (electrodos).

En ambos tipos de registros, la mitad de los canales son conectados del lado del hemisferio derecho, y la otra mitad son conectados al hemisferio izquierdo. De esta manera, es posible comparar de a simple vista dos áreas homólogas del cerebro [25].

1.1.2.1. Registro monopolar o referencial

Cada electrodo capta de manera independiente su diferencia de potencial. El sensor (electrodo activo) realiza la lectura del voltaje en un punto determinado respecto a un electrodo referencial con voltaje igual a cero. En la práctica se suelen ubicar los electrodos referenciales en los mastoides, lóbulos de las orejas, o mentón, y a pesar de no tener un voltaje nulo, igualmente reducen de manera considerable la detección de actividad eléctrica del cerebro [25].

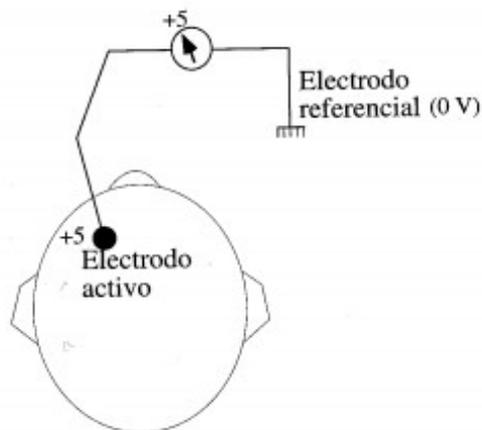


Figura 4. Montaje monopolar de EEG [26]

1.1.2.2. Registro Bipolar

A diferencia del tipo de registro monopolar, el registro bipolar logra medir las señales procedentes de parejas de electodos activos, para posteriormente restar los valores de voltaje y así eliminar la actividad entre ellos. Debido a este tipo de registro, no se produce ninguna contaminación en los registros, a pesar de que supone la pérdida de gran parte de la información [17].

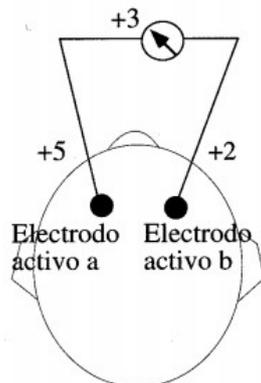


Figura 5. Montaje bipolar de EEG [26]. El electrodo A mide +5V, electrodo B mide +2V, por lo tanto, el voltaje bipolar (diferencial) es $(+5V) - (+2V) = 3V$.

1.1.3. TIPOS DE ONDAS EN EL EEG

En las diferentes zonas del cerebro podemos encontrar más actividad eléctrica relacionada a una actividad u otra, por ejemplo, es de esperarse que en el lóbulo occipital (el cuál es el encargado de la visión) exista más información relacionada con la apertura y cierre de ojos, mientras que en el lóbulo frontal se esperaría encontrar más información relacionada al desarrollo de problemas.

Es muy importante conocer el comportamiento de estas ondas ya que pueden brindar información importante acerca de algunas tareas cognitivas que se pueden estar llevando a cabo por las personas. La tabla 2 asocia las diferentes bandas de frecuencia con las características de cada una de las ondas del EEG. Además, muestra las fuentes que originan estas ondas, es decir, la tarea cognitiva que se puede estar realizando [16].

Tipo de Onda	Banda de frecuencias	Características
Delta	< 4 Hz	Ondas de amplitud variable asociadas al sueño profundo y la meditación.
Theta	4 – 7 Hz	Ondas de amplitud menor a 20 microvoltios asociadas al estrés y la frustración.
Alpha	7 – 13 Hz	Ondas de amplitud menor a 20 microvoltios asociadas a la relajación y a los ojos cerrados.
Mu	7– 13 Hz	Ondas presentes en la zona sensoriomotora. Se atenúan durante el movimiento o intento de movimiento de extremidades. Son espontáneas.
Beta	14 – 39 Hz	Ondas de amplitud variable asociadas a la concentración y resolución de problemas. Puede alcanzar los 50 Hz cuando la persona se encuentra en un estado de concentración extrema.
Gamma	> 40 Hz	Ondas de amplitud variable asociadas a la comunicación y a tareas mentales de alta complejidad.

Tabla 2. Clasificación de los diferentes tipos de onda según sus bandas de frecuencia y sus características. Autoría propia.

1.1.4. CORTEZA MOTORA

La corteza motora se encuentra ubicada por delante del surco central del cerebro, de manera que ocupa alrededor de un tercio de los lóbulos frontales. Justo detrás del surco central se encuentra la corteza sensitiva somática, quien envía las señales que controlan las actividades motoras, a la corteza motora. Es decir, que la corteza motora es la encargada de la planificación, control, y ejecución de casi todos los movimientos voluntarios [27]. La figura 6 muestra las diferentes zonas del cerebro asociadas a tareas cognitivas.

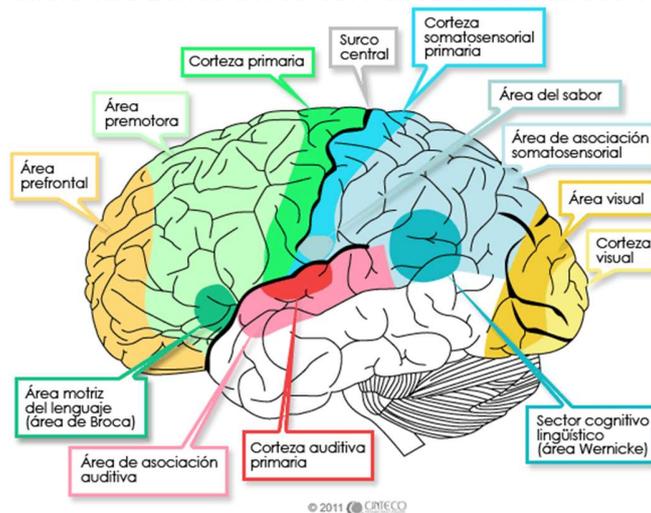


Figura 6. Divisiones asociadas a las diferentes tareas cognitivas [27]. En verde y azul, la corteza motora.

La estimulación eléctrica en diferentes partes de la corteza cerebral produce la contracción de un grupo de músculos específicos. En los años 50 Wilder Penfield realizó dicha estimulación sobre la corteza cerebral y notó que cada zona de la corteza correspondía a un grupo de músculos responsables del movimiento en una parte específica del cuerpo [27]. Estos resultados son representados gráficamente por medio de lo que denominó homúnculo motor (Ver figura 7).

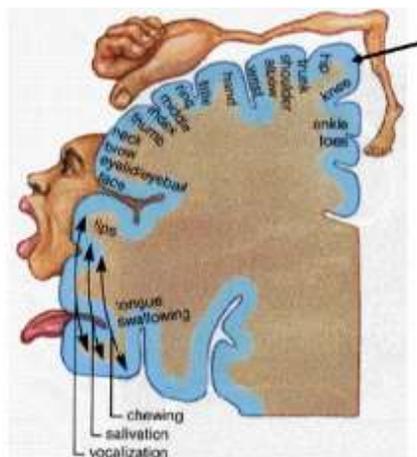


Figura 7. Homúnculo Motor [27].

1.1.5. SISTEMA INTERNACIONAL 10-20

Es el sistema más utilizado hoy en día para el posicionamiento de electrodos superficiales para captar señales EEG. Fue desarrollado con el fin de generar un estándar y repetitividad en la toma de datos, permitiendo comparar estudios realizados a lo largo del tiempo [22]

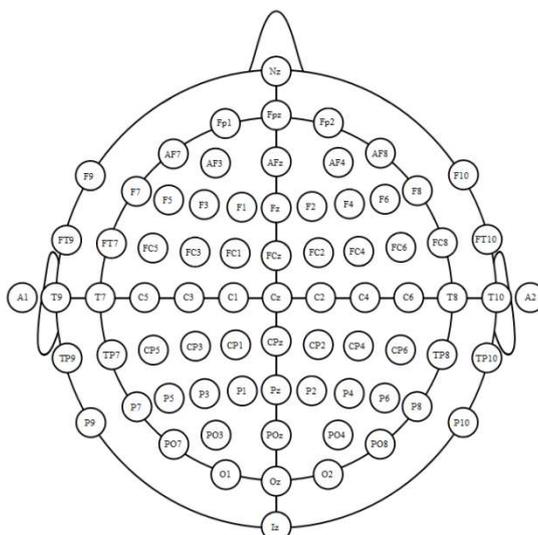


Figura 8. Posicionamiento de los electrodos superficiales bajo es sistema internacional 10-20 [28]

Para ubicar los electrodos es necesario conocer la longitud del cráneo medida desde el nasión hasta el inión pasando por el vértex. Posteriormente se toma el 10% de esta medida para ubicar los electrodos proximales al inión y al nasión, luego, a partir de la ubicación de estos dos electrodos (Fpz y Oz) se ubican los demás, utilizando una separación entre ellos del 20% de la medida original.

La letra empleada para denominar cada uno de los electrodos significa el lóbulo al cual pertenece (F: Frontal, O: Occipital, P: Parietal, T: Temporal, y C: Línea horizontal central), mientras que los números indican el hemisferio al cual pertenecen, los números impares para el hemisferio izquierdo y los pares para el hemisferio derecho. El subíndice 'z' indica que el electrodo hace parte de la línea vertical central [28].

1.1.6. RITMOS SENSORIOMOTORES (SMR)

Los ritmos sensoriomotores son señales oscilatorias presentes en la corteza motora, asociados a procesos de actividad motora y sensorial, tal como lo es el movimiento o su imaginación. Es posible observarlos en los ritmos mu (7 Hz – 13 Hz) y beta (14 Hz – 39 Hz). Cuando se genera el movimiento o la imaginación de movimiento de una extremidad, se refleja la actividad sensoriomotora en el hemisferio contralateral al miembro de interés. Esta actividad es denominada como ERD (Desincronización relacionada a evento), la cual es una disminución en la energía a lo largo de una banda de frecuencias en la posición específica de generación, por su parte, los ERS (Sincronización relacionada a evento) se manifiestan como un aumento en la energía y ocurren posterior a la generación [29].

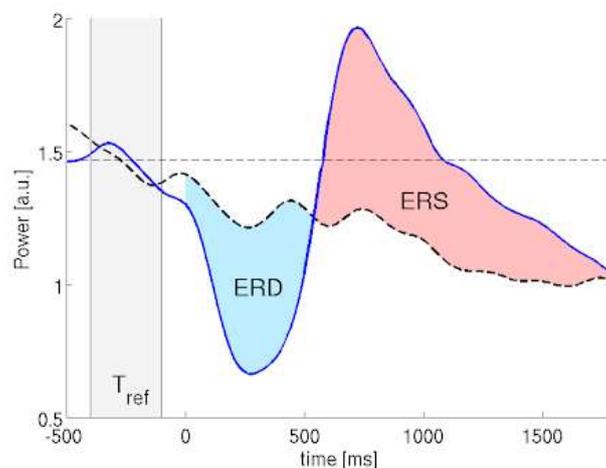


Figura 9. Potenciales ERD y ERS cuando el estímulo es generado en tiempo igual a cero [30].

1.1.7. APRENDIZAJE AUTOMÁTICO

El aprendizaje automático o comúnmente conocido como *Machine Learning*, hace referencia a una estrategia de inteligencia artificial que permite que los sistemas adquieran su propio conocimiento al extraer determinados patrones de datos.

El aprendizaje automático tiene la capacidad de predecir nuevos casos, a partir de la experiencia adquirida al analizar un caso conocido, a este proceso se le conoce como generalización [30]. Las diferentes técnicas se dividen en dos tipos de aprendizaje: supervisado y no supervisado.

1.1.7.1. Aprendizaje supervisado

Se emplea información conocida para clasificar los datos, que posteriormente son analizados por los algoritmos de *aprendizaje automático*. Es decir que cada una de las muestras a analizar está relacionada con una variable que indica que etiqueta tiene dicha muestra.

Este tipo de aprendizaje se subdivide en clasificación y regresión. Cuando se habla de clasificación, se dice que las salidas del sistema son finitas, discretas, e interpretables. Mientras que en la regresión se obtienen salidas continuas [31]. En otras palabras, un grupo de datos etiquetado previamente permite predecir la etiqueta de un nuevo grupo de datos desconocido [29] [25]. La Figura 10 muestra cómo se implementa un sistema de aprendizaje automático de aprendizaje supervisado.

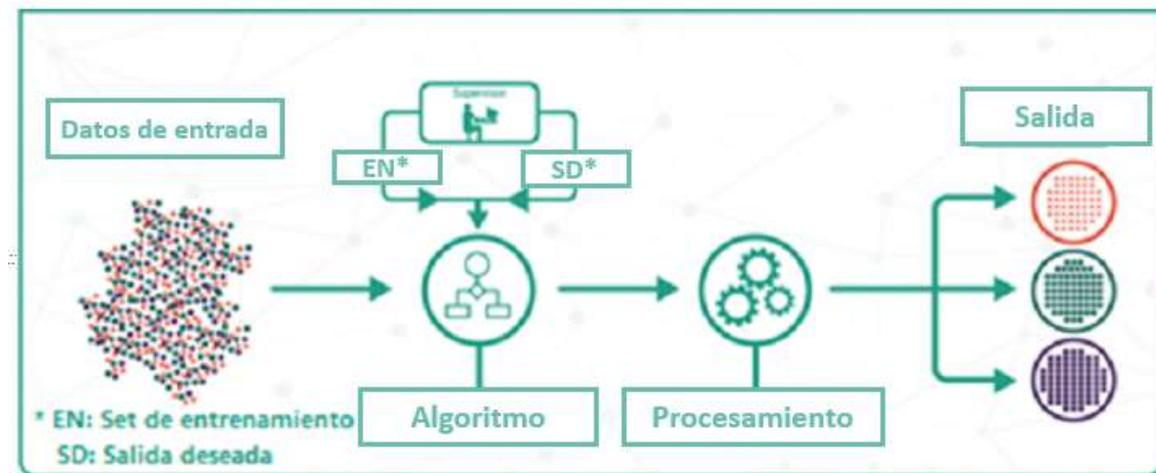


Figura 10. Proceso de clasificación en el tipo de aprendizaje supervisado [32].

1.1.7.2. Aprendizaje no supervisado

Es un conjunto de técnicas, en dónde se dispone de los datos de entrenamiento (a etiquetar), más no de los datos de prueba (etiquetados), es decir que, al no existir un grupo objetivo se buscarán patrones que permitan encontrar estructuras y asociación en los datos, infiriendo modelos para ello.

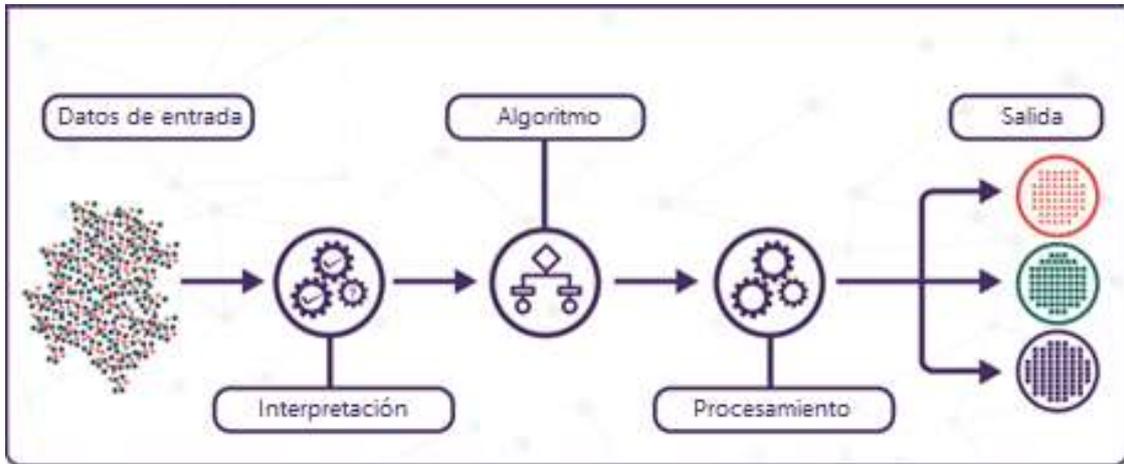


Figura 11. Proceso de clasificación en el tipo de aprendizaje no supervisado [32].

1.1.7.3. Entrenamiento y evaluación en aprendizaje automático

El entrenamiento se define como el proceso mediante el cual se ajustan los parámetros libres de un modelo estadístico para minimizar la una función de error sobre el conjunto de datos [33].

Cuando se trabaja sobre un conjunto de datos para predecir o clasificar un problema, es común encontrar la exactitud del algoritmo, para después ir la mejorando por medio de variaciones del modelo, o del ajuste en la selección de datos. Sin embargo, antes de realizar nuestro modelo, o de rediseñarlo, se debe tener en cuenta que se pueden tener diferentes casos respecto a la generalización de los datos.

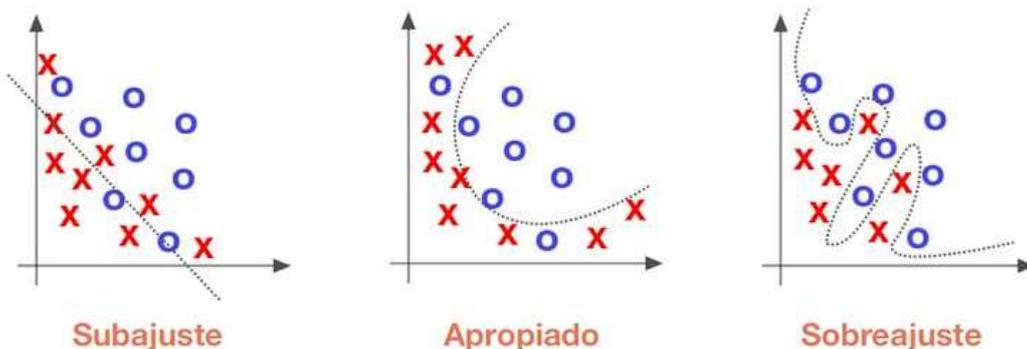


Figura 12. Separación de los datos por medio de una función de decisión [34].

Como se puede observar en la figura 12 se tienen tres casos para la generalización de los datos. Cada una de ellas dependerá del número de muestras a analizar, el número de características, y de la función de decisión realizada por el algoritmo de clasificación.

Existen dos tipos de comportamientos erróneos que se pueden tener a la hora de realizar un algoritmo de clasificación.

1.1.7.4. Subajuste

Ocurre cuando un modelo no puede modelar los datos de entrenamiento para predecir nuevos datos. Se debe a que el modelo de *aprendizaje automático* es demasiado simple, lo que destruye la exactitud del modelo, ya que el modelo o algoritmo no se ajusta a los datos lo suficientemente bien.

Suele ocurrir cuando se desea construir un modelo (borde de decisión) lineal, y la distribución de los datos es no lineal, también cuando la cantidad de datos para construir el modelo no es lo suficientemente grande, lo que lleva a realizar una mala generalización [33]. Una manera de solucionarlo es aumentando el número de datos a analizar, o reduciendo el número de características sobre los datos.

1.1.7.5. Sobreajuste

Ocurre cuando el sistema es capaz de modelar los datos demasiado bien, es decir, el modelo no solo aprende sobre las características necesarias para la predicción, sino también aprende sobre las características que se desean evitar, como el ruido.

Esto significa que bien sea el ruido, o algunas fluctuaciones aleatorias en los datos son aprendidas por el modelo, lo que conlleva a una mala generalización, ya que dicha fluctuación o dicho ruido no será el mismo en un grupo de datos diferente. Es más probable que se de en modelos no paramétricos, ya que tienden a construir aproximaciones poco realistas, debido a la libertad que tienen para construir el modelo [35].

Existen diferentes técnicas que son útiles para prevenir estos casos de generalización, como lo son las técnicas de validación, el aumento en el set de datos de prueba, la regularización del modelo, o la detección temprana del decrecimiento en el rendimiento del algoritmo.

1.1.7.6. Validación cruzada

Consiste en tomar la información del set de datos, y a partir de ellos construir dos conjuntos separados, un conjunto de prueba, y un conjunto de prueba o validación. Posteriormente, el conjunto de prueba se divide en k subconjuntos, y, al momento de realizar el entrenamiento, se toma cada k conjunto como prueba para el modelo, mientras que los otros subconjuntos se toman como set de prueba.

El proceso se repite k veces, y en cada iteración se selecciona un conjunto k de prueba diferente. Cuando se repite el proceso para cada uno de los subconjuntos, se calcula la exactitud y el error para cada uno de modelos producidos, estos valores son promediados y así se obtiene la exactitud y error general del sistema (Ver figura 13) [33] [34].

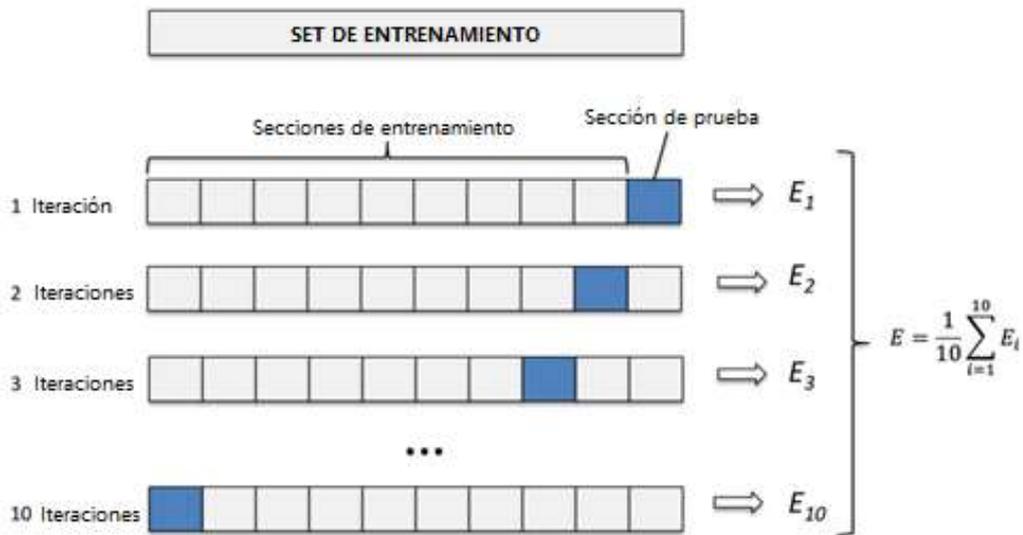


Figura 13. Selección de datos de entrenamiento y prueba en la validación cruzada *k-folds* con $k = 10$. [36].

Este método de evaluación del algoritmo permite identificar si existe un caso de sobreajuste, ya que, al momento de probar la clasificación con los datos de prueba, la exactitud del algoritmo tenderá a disminuir de manera notoria. Al mismo tiempo, permite evaluar la generalización del modelo entrenado ante nuevas entradas, mostrando que no se está especializando el modelo a los datos de entrenamiento.

1.1.7.7. Métricas de clasificación

Para validar el desempeño de los algoritmos de aprendizaje automático se requiere usar métricas de validación como las matrices de confusión, exactitudes, sensibilidades, y especificidades, ya que permite entender de mejor manera el comportamiento del algoritmo de clasificación. A continuación, se explican algunas de las métricas más empleadas para evaluar algoritmos de aprendizaje automático [37].

Precisión:

$$\text{Precisión: } \frac{\text{Clasificaciones exitosas}}{\text{Número total de muestras}} \quad (1)$$

A partir de la precisión, es posible calcular la matriz de confusión de la clasificación, la cual permite realizar otro tipo de cálculos como la sensibilidad y la especificidad. Además, permite comprender de mejor manera el desempeño de cada algoritmo, al brindar información sobre qué porcentaje de muestras se clasificaron de manera correcta o incorrecta.

En una matriz de confusión las filas corresponden a las clases reales, y las columnas a las clases predichas. Es decir, en una clasificación binaria, una matriz de confusión tendría cuatro entradas. Cada una de las entradas corresponde a la precisión a la hora de clasificar

dicha clase (predicha) respecto a la clase real. En la figura 14 se puede observar un ejemplo de una matriz de confusión y cómo cada una de las entradas son calculadas.

Clase real	A	VP <i>Número de clases 'A' predichas</i> <i>Total de clases 'A' reales</i>	FN <i>Número de clases 'B' predichas</i> <i>Total de clases 'A' reales</i>
	B	FP <i>Número de clases 'A' predichas</i> <i>Total de clases 'B' reales</i>	VN <i>Número de clases 'B' predichas</i> <i>Total de clases 'B' reales</i>
		A	B
		Clase predicha	

Figura 14. Ejemplo de una matriz de confusión bi-clase. Autoría propia.

Cada uno de los títulos en las entradas de la matriz corresponde a como comúnmente se le conoce a cada una de ellas en una clasificación de tipo Falso – Verdadero. Por ejemplo, si el modelo buscara predecir si un sujeto tuvo o no intención de movimiento, en caso de que exista la intención se toma como un caso verdadero, y en caso de que no exista la intención de movimiento, se toma como un caso falso. Por lo tanto, VP hace referencia al porcentaje de verdaderos positivos (intenciones de movimiento detectadas de forma correcta), FN al porcentaje de falsos negativos (no se detectó intención de movimiento cuando si había intención de movimiento), FP al porcentaje de falsos positivos (se detectó intención de movimiento cuando no había intención de movimiento), y VN al porcentaje de verdaderos negativos (no se detectó intención de movimiento de manera correcta) [37].

Exactitud:

$$Exactitud = \frac{VP + VN}{VP + FN + FP + VN} \quad (2)$$

Sensibilidad:

$$Sensibilidad = \frac{VN}{VN + FP} \quad (3)$$

Especificidad:

$$Especificidad = \frac{VP}{VP + FN} \quad (4)$$

1.1.7.8. Máquinas de soporte vectorial (SVM)

Las máquinas de soporte vectorial o SVM por sus siglas (*Support Vector Machine*) son unas de las técnicas de aprendizaje automático supervisado más utilizadas para la detección de intención de movimiento [38]. Fue propuesto por Vladimir N. Vapnik y Alexey Y. Chervonenkis en 1963, cuándo realizaron un clasificador que aprovechaba las características de los Kérnels, permitiendo un margen m mayor entre el conjunto de datos mediante la generación de hiperplanos.

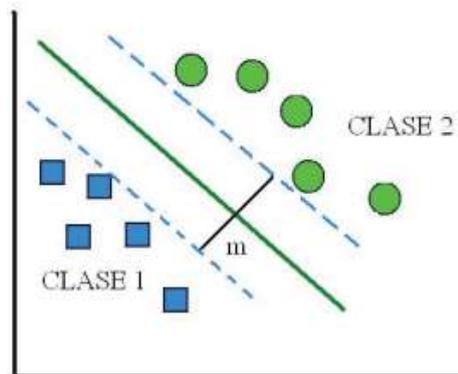


Figura 15. Margen de separación entre dos clases. [31]

El principio de operación de las máquinas de soporte vectorial está basado en la creación de una función lineal en un espacio multidimensional que separe las clases. Dicha función (ecuación 5) es generada por el mapeo no lineal de un vector M -dimensional en un espacio K -dimensional.

$$g(x) = w^T \varphi(x) + b \quad (5)$$

En dónde, φ está dada por un vector de características, b es el sesgo del sistema, y W como el vector de pesos de la red.

El aprendizaje de las SVM se enfoca en la maximización de del margen de separación entre dos o más clases, las cuales se denotarán como $d1 = 1$, y $d2 = -1$. Esta maximización, implica matemáticamente una minimización del costo de la función $\varphi(w, \varepsilon)$ con $\varepsilon > 1$ y $C > 0$, definida como:

$$\min \varphi(w, \varepsilon) = \frac{1}{2} * W * W^T + C * \sum_{i=1}^P \varepsilon_i \quad (6)$$

Con:

$$d_i(W^T * \varphi(x) + b) \geq 1 - \varepsilon_i \quad (7)$$

Las SVM mapean los elementos del conjunto original σ , de entrada, a un espacio de características de dimensión mayor, es decir, si los puntos de entrada se encuentran en R^2 ,

son mapeados en R^3 . Posteriormente, se busca un hiperplano que separe y aumente el margen entre las clases del espacio.

Sin embargo, en la ecuación 6, C debe ser un conjunto linealmente separable con tal de que las siguientes inecuaciones se cumplan para todos los elementos del conjunto

$$\begin{cases} (w^T \cdot \varepsilon_i + b) \geq 1, & d_i = 1 \\ (w^T \cdot \varepsilon_i + b) \geq -1, & d_i = -1 \end{cases} \quad (8)$$

En caso de que los datos no sean linealmente separables, existe la posibilidad de transformar los datos a un espacio de mayor dimensión, en dónde, de igual manera, se buscará un hiperplano $k(x)$ óptimo para separar las clases. La frontera de decisión resultante en el espacio de entrada ya no será lineal y estará dada por otro tipo de funciones denominadas *kernels*.

Una vez que las muestras son proyectadas en el espacio de mayor dimensión Ψ , se aplica el *kernel*, cuyo punto de partida está en R^d , y depende del vector de características φ . Por lo tanto, la frontera de separación estará definida de la siguiente manera:

$$K(x_i, x_j) = k(\varphi(x_i)) \cdot k(\varphi(x_j)) \quad (9)$$

Por lo tanto, no se necesitará conocer explícitamente la transformación $k(x)$, o incluso el espacio dimensional Ψ , ya que la única condición es que la función *kernel* esté bien aplicada. Los *kernels* pueden ser funciones gaussianas, sigmoideas, polinómicas de grado mayor a 1, entre otras.

Cuando se desean separar más de dos clases en una SVM, se requiere de hacer el proceso de clasificación uno-vs-uno o uno-vs-todos, es decir, si se tienen tres clases A, B y C, se clasificarán de maneras independientes de la forma A vs B, B vs C, y A vs C, o de la forma A vs nueva clase BC, B vs nueva clase AC, y C vs nueva clase AB.

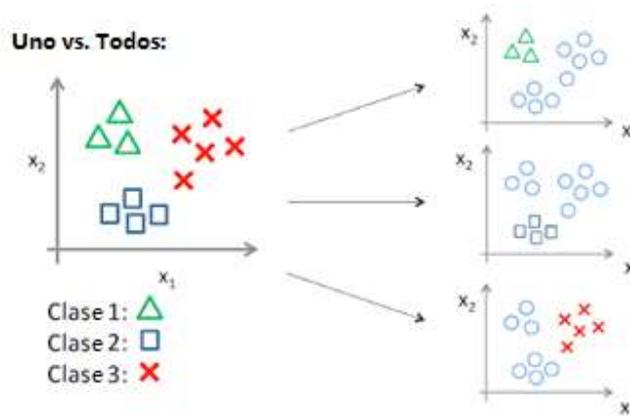


Figura 16. Clasificación multiclase tipo uno-vs-todos. [31]

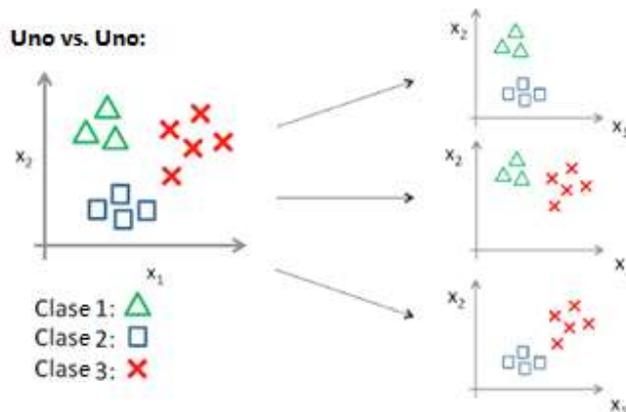


Figura 17. Clasificación multiclase tipo uno-vs-uno. [31]

1.1.7.9. Agrupación por K vecinos más cercanos (Knn)

La idea central y básica de este algoritmo es clasificar una nueva muestra según la cantidad de K vecinos más cercanos clasificados en una u otra clase. Por lo tanto, el paradigma se basa en una idea bastante intuitiva, permitiendo una fácil interpretación. [39]

Para llevar a cabo la clasificación, la nueva muestra M1 se ubica en un subespacio de clasificación en dónde se encuentran las diferentes muestras. A partir de la ubicación de la nueva muestra M1, se mide la distancia de M1 a las demás muestras y se eligen las K más cercanas. Posteriormente, se determina a qué clase pertenecen las K muestras más cercanas, y la nueva clase de M1 será determinada por la clase a la que pertenezcan la mayoría de las K muestras.

En la figura 18, se puede observar un ejemplo gráfico de la agrupación por K vecinos más cercanos. En dónde se tienen un total de 24 muestras, de las cuales 13 corresponden a la clase '+', y 11 corresponden a la clase 'o'. Para el presente caso se utiliza un K=3, por lo que solo se tendrán en cuenta las 3 muestras más cercanas a la nueva muestra '•'.

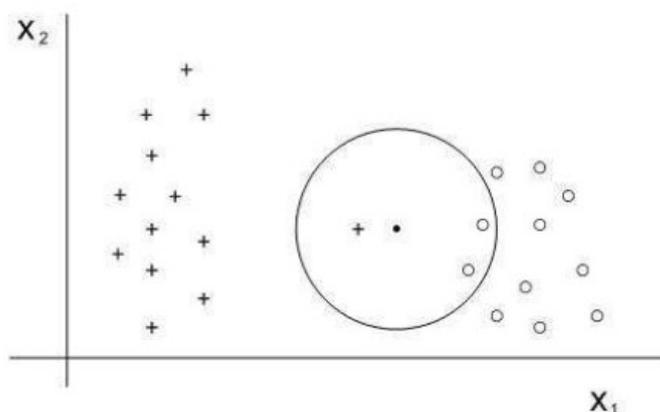


Figura 18. Ejemplo de aplicación del algoritmo de K-nn. [39]

Al tomar únicamente las 3 muestras más cercanas a la nueva muestra, y teniendo en cuenta que es un ejercicio de clasificación bi-clase, el diseñador se asegura de que no exista un empate en cuánto a la clasificación de las K muestras seleccionadas, y por lo tanto a la nueva muestra se le otorga la clase 'o'.

Sin embargo, esto no significa que en varios casos se dé un empate en cuánto a las clases de las K muestras seleccionadas [40]. Por lo que se debe seleccionar un método heurístico de desempate. Dentro de las reglas de desempate se pueden encontrar un gran número de métodos, como lo son: seleccionar al vecino más cercano, la clase con menor distancia, la clase con menor o mayor índice, etc.

Existen diferentes versiones del algoritmo, en las cuales se realizan modificaciones de la técnica principal con el fin de generalizar el algoritmo usado y que su rango de aplicación sea mayor. Una versión de ellas es la agrupación fina por K vecinos más cercanos, la cual consiste en realizar la clasificación de la nueva muestra, tomando un número de vecinos igual a 1. Por lo tanto, la clase de la nueva muestra será igual a la clase de la muestra más cercana.

1.1.7.10. Árboles de decisión

Es uno de los algoritmos de aprendizaje automático más comúnmente usados ya que le permite al usuario visualizar y entender lo que está sucediendo. Es una estructura similar a la de un diagrama de flujo, en dónde cada nodo interno representa una característica, la rama representa una regla de decisión, y cada hoja, el resultado. En la figura 19 se puede observar una estructura corta de un árbol de decisión, el cual está compuesto por 12 nodos, 11 ramas, y finalmente, siete hojas.

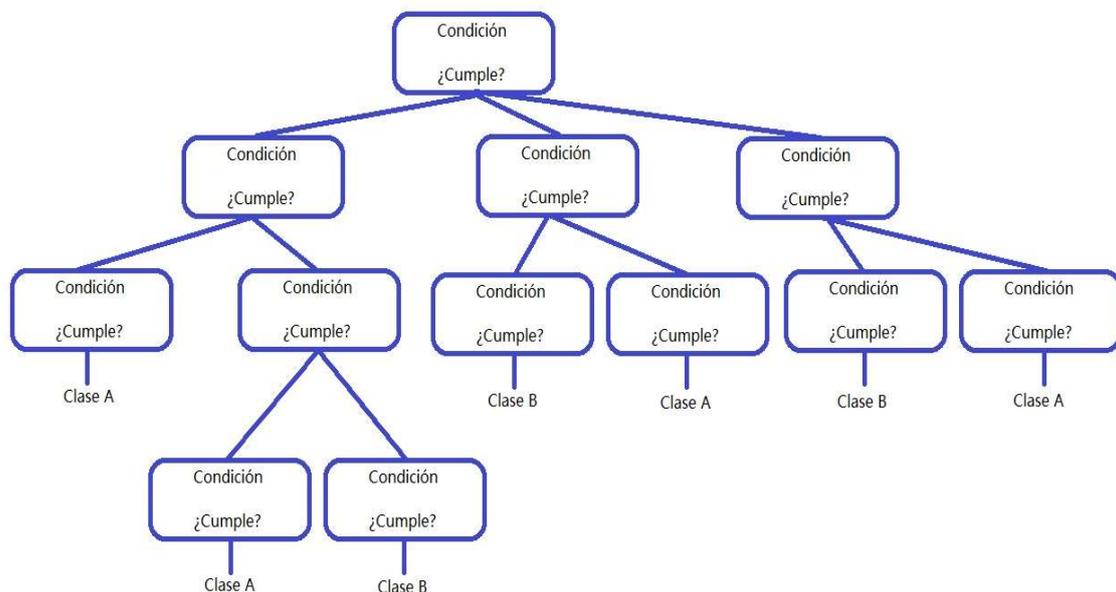


Figura 19. Estructura y concepto de un árbol de decisión. Autoría propia.

La idea básica de un árbol de decisión consiste en seleccionar el mejor atributo empleando una medida de selección determinada, luego, este atributo se convierte en un nodo de decisión, dividiendo el conjunto de datos en subconjuntos de datos más pequeños. Posteriormente, el proceso se repite consecutivamente hasta realizarlo con todos los atributos, o hasta que todas las variables pertenezcan al mismo atributo, es decir que no existen más casos.

A cada uno de los atributos o características, se les es asignado una regla de partición, es decir, un rango que le permite determinar al nodo si se cumple o no con la condición, modificando así las reglas de decisión para cada caso.

Como en métodos de clasificación anteriores, los algoritmos típicos suelen ser modificados con el fin de generalizar el método, y darle un uso en aplicaciones más variadas. Las técnicas más comunes suelen ser llamadas técnicas de ensamblaje, y se encuentran en varios tipos, como lo es el método de *bagging*.

En principio, los métodos de ensamblaje combinan las predicciones de múltiples modelos de aprendizaje automático con el propósito de brindar una mejor predicción respecto a los modelos individuales empleados para su uso. Más comúnmente llamada como *Bootstrap Aggregation*, la técnica de *bagging* es un procedimiento que es utilizado para disminuir la varianza de los algoritmos.

Los árboles de decisión son sensibles a los datos específicos con los que fueron entrenados, es decir, si los datos de prueba varían demasiado respecto a los datos de entrenamiento, el modelo puede aumentar las veces que predice de manera incorrecta una clase. Es por eso, que la técnica de *bagging* plantea la creación de varios árboles de decisión, que luego, a través de un árbol de decisión final reduce la varianza entre ellos, entregando una mejor exactitud en los resultados.

Las desventajas de emplear este tipo de algoritmo se centran en que, como se mencionó anteriormente, el modelo tiende a ser muy sensible a las variaciones en la entrada, por lo que, una pequeña variación en los datos puede dar lugar a un árbol de decisión diferente, sin embargo, es uno de los pocos modelos de aprendizaje automático en los cuales es posible comprender como se da la toma de decisiones en el algoritmo.

2. OBJETIVOS

2.1. General

Detectar la intención de movimiento en miembros superiores a partir de señales de EEG empleando técnicas de aprendizaje automático.

2.2. Específicos

- 2.2.1 Realizar una revisión del estado del arte en el contexto de técnicas de aprendizaje automático para detectar intención de movimiento.
- 2.2.2 Obtener una base de datos a partir de 5 sujetos sanos que imaginen movimiento en miembro superior, a partir de señales de EEG adquiridas a través de un dispositivo de adquisición apropiado.
- 2.2.3 Detectar la intención de movimiento en señales de EEG a partir de la extracción de características temporales y frecuenciales apropiadas.
- 2.2.4 Evaluar tres diferentes técnicas de aprendizaje automático supervisado, por medio del uso de métricas de clasificación adecuadas.

3. METODOLOGÍA

La detección de intención de movimiento se puede realizar por medio del uso de registros electroencefalográficos adquiridos en la corteza primaria motora, ya que allí es donde se contiene la información necesaria sobre los procesos de generación de movimiento en las extremidades. Posteriormente, estos registros deben ser pre procesados y procesados con el fin de obtener las características adecuadas para predecir la intención de movimiento, la cual será clasificada por medio de técnicas de aprendizaje automático, y evaluada por métricas de evaluación que permitan determinar la funcionalidad del algoritmo. Esta serie de procesos se llevaron a cabo por medio del software Matlab, debido a su facilidad de uso para desarrollar tareas de clasificación automática. En esta sección se presentan de manera detallada las diferentes etapas empleadas para realizar la clasificación.

3.1. Base de datos

Para llevar a cabo el estudio se decidió hacer uso de una base de datos relacionada a intención de movimiento, en la cual emplearon el dispositivo de adquisición g.Nutilus de la empresa g.Tec, debido a su fiabilidad en el campo de la investigación, y a que permite realizar la lectura de la actividad cerebral en zonas cercanas a la corteza primaria motora.

El g.Nutilus tiene un total de 32 electrodos activos ubicados según el sistema de referencia 10-20, que proveen información a una tasa de 250 muestras por segundo. Sin embargo, para el propósito de este estudio solo se analizarán los registros de tres diferentes canales, debido a su cercanía con la corteza primaria motora [41]. Estos canales son C3, Cz, y C4. Además, se resalta que a la hora de adquirir los datos la muestra inicial y final no fueron tomadas en cuenta, por lo que la frecuencia de muestreo real fue de 248 muestras por segundo.

Dentro de los criterios de inclusión de la base de datos, se tuvieron en cuenta a sujetos sanos sin ninguna patología neurológica reportada. Las edades de los sujetos estaban comprendidas entre los 23 y 28 años. La totalidad de ellos fueron informados sobre el procedimiento a realizar, y accedieron a participar por medio de su firma en un consentimiento informado.

Todos los sujetos realizaron el procedimiento, y sus datos fueron almacenados por medio de un registro de grabación. Cada registro tiene una duración de 108 segundos y se compone de 10 experimentos registrados de manera continua, los cuales tienen información de cuatro diferentes tipos de movimiento: Descanso, relajación, e imaginación motora de miembro superior derecho e izquierdo. La indicación para realizar estos cuatro tipos de movimiento se mostraba al sujeto por medio de una pantalla, la cual informaba al sujeto en qué momento realizar los diferentes tipos de imaginación motora (ver Figura 20).

Cabe resaltar, que la base de datos creada por (Triana, Orjuela-Cañón, & Jutinico, 2019), también fue empleada para realizar un estudio con propósitos similares a este. Obteniendo exactitudes en la clasificación de hasta 68% [18]. Sin embargo, solo emplearon los datos de un sujeto para realizar la clasificación de imaginación motora, y las técnicas de aprendizaje automático empleadas fueron diferentes a las del actual estudio.

Cada experimento tiene una duración de nueve segundos, de los cuales tres segundos corresponden a un estado de descanso, tres a imaginación motora, y los últimos tres a relajación. La indicación de imaginación motora se realizó de manera aleatoria y equivalente a lo largo de los experimentos de cada registro. Es decir, cinco experimentos contienen la imaginación de movimiento en la mano derecha, y otros cinco de imaginación de movimiento en la mano izquierda.

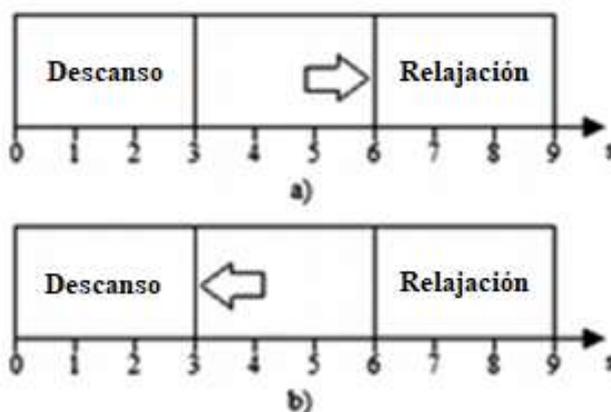


Figura 20. Los dos diferentes tipos de experimento en cada uno de los registros. A) corresponde a imaginación motora de puño izquierdo. B) corresponde a imaginación motora de puño derecho. [18]

Es necesario resaltar que durante el estado de relajación a los sujetos se les permitía parpadear y realizar movimientos leves de ser necesario, mientras que en el estado de descanso dichas acciones estaban prohibidas. Es decir que es más probable encontrar un mayor componente de ruido en el estado de relajación que en el estado de descanso. Por lo cual, se decidió clasificar únicamente tres estados: imaginación motora de mano derecha, imaginación motora de mano izquierda, y estado de descanso.

Como primera medida, a todas las señales se les aplicó un filtro pasabanda entre 0.5 Hz y 45 Hz, ya que los componentes frecuenciales relacionados con la corteza motora primaria se encuentran en esta banda de frecuencias [12]. Posteriormente, se removió la tendencia de las señales, con el fin de trabajar con una base fija y evitar variaciones de amplitud que puedan afectar la información de los registros.

Cada una de las señales seleccionadas fue dividida en ventanas de medio segundo sin traslape, permitiendo evaluar de manera más frecuente a lo habitual cada intervalo de las señales, ya que generalmente se emplean divisiones de un segundo o más como en los estudios de (Alomari, Samaha, & AlKamba, 2013), (Bamdad, Zarshenas, & Mohammad, 2015), y (Pulido & López, 2017), entre otros [15] [14] [12]. A cada una de estas ventanas se le extrajeron diferentes características en el dominio del tiempo y dominio de la frecuencia. En la tabla 3 se pueden observar de manera más clara cómo se realizó la adecuación de la base de datos.

	Canal		
	CZ	C3	C4
# de Experimentos por sujeto	10		
Duración de experimento (segundos)	6		
Muestras por experimento (Fs*Duración del experimento)	1488		
Muestras por canal (Muestras por experimento * # experimentos)	14880		
Tamaño de la ventana (segundos)	0,5		
Tamaño de ventana en muestras (Fs*Tamaño de la ventana)	124		
# de Ventanas (Muestras por canal/ Tamaño ventana)	120		

Tabla 3. Adecuación de las señales para la posterior extracción de características.
Fs : Frecuencia de Muestreo. #: Número

3.2. Extracción de características

Como se ha mencionado previamente, se busca determinar qué tipo de características son más útiles para realizar la detección de la imaginación de movimiento. Para realizar la comparación de las dos fuentes de características como lo son las del dominio del tiempo y frecuencia, cada tipo de estas características fue obtenido de diferente forma, la Tabla 4 muestra los dos dominios empleados y las características usadas en cada uno.

Dominio	Clase
Tiempo	Media, varianza, asimetría, curtosis, movilidad y complejidad de Hjorth.
Frecuencia	Valor medio cuadrático, densidad espectral de potencia por bandas ($\Delta, \theta, \alpha, \beta, \gamma$).

Tabla 4. Características extraídas según el dominio.

La justificación de la elección de estas características se debe a que en estudios anteriores se han presentado resultados exitosos haciendo uso de algunas de las características seleccionadas [42] [43]. Además, cada una de las ecuaciones que describe a las características se encuentran a continuación.

Media:

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (10)$$

Varianza:

$$S_x^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (11)$$

Asimetría estadística:

$$CA_F = \frac{1}{N * S_x^3} \sum_{i=1}^N (x_i - \bar{x})^3 \quad (12)$$

Curtosis:

$$Curtosis = \left[\frac{1}{N * S_x^4} \sum_{i=1}^N (x_i - \bar{x})^4 \right] - 3 \quad (13)$$

Parámetros de Hjorth:

- Actividad: $Act = S_x^2$
- Movilidad: $Mob = \sqrt{\frac{Actividad \left(\frac{dx(t)}{dt} \right)}{Actividad(x(t))}} \quad (14)$
- Complejidad: $Com = \frac{Movilidad \left(\frac{dx(t)}{dt} \right)}{Movilidad(x(t))}$

Valor Medio Cuadrático:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^n x_i^2} \quad (15)$$

Para obtener el valor de las potencias relativas por banda fue necesario realizar el cálculo de la Densidad Espectral de Potencia (PSD), ya que permite cuantificar qué tanta potencia existe en cada una de las bandas del EEG. Para calcular la PSD se empleó una ventana de 0.5s al igual que las ventanas de seccionamiento utilizadas para calcular las demás características, y un traslape del 50% entre ventanas.

Posteriormente, se procedió a realizar una clasificación cada medio segundo según la intención de movimiento del sujeto. Las diferentes clasificaciones se pueden observar en la tabla 5.

Intención de movimiento	Etiqueta
Mano derecha (Abrir y cerrar)	1
Descanso	0
Mano izquierda (Abrir y Cerrar)	-1

Tabla 5. Selección de la clase categórica según la imaginación de movimiento.

Por lo tanto, para cada medio segundo (correspondientes a segmentos de 124 muestras cada uno) se realiza el cálculo de las características previamente seleccionadas, ubicándolas en una matriz en donde las filas corresponden a cada una de las ventanas de tiempo, y las columnas, a cada una de las características.

Con el fin de analizar qué tipo de características son más relevantes a la hora de clasificar la imaginación motora de miembros superiores, de acuerdo con la presente investigación, se elaboraron dos matrices de características. Una con características temporales, y otra con características frecuenciales.

Adicionalmente, con el fin de reconocer qué diferencias existen en el desempeño de los algoritmos a la hora de clasificar únicamente imaginación motora, independientemente del miembro en el cual se realice la acción, se realizó una segunda clasificación en la que solo se tienen dos clases: '1' para imaginación motora, y '0' para estado de descanso.

Por lo cual, se tienen cuatro matrices de características, cada una compuesta por 18 características (6 por canal) y 120 instancias (Número de ventanas). Las matrices son separadas en dos grupos. El primero se conforma por las matrices que contienen las características temporales con dos y tres clases, y el segundo con las matrices correspondientes a las características frecuenciales con dos y tres clases. En la tabla 6 se observa cómo se construyeron los cuatro diferentes modelos de clasificación según el dominio y las clases empleadas.

		CLASIFICACIÓN					
		DOS CLASES			TRES CLASES		
		CARACTERÍSTICAS		Número de instancias	CARACTERÍSTICAS		Número de instancias
		Por canal	Total		Por canal	Total	
DOMINIO	Tiempo	Media	18	120	Media	18	120
		Varianza			Varianza		
		Complejidad de Hjorth			Complejidad de Hjorth		
		Movilidad de Hjorth			Movilidad de Hjorth		
		Asimetría			Asimetría		
		Curtosis			Curtosis		
	Frecuencia	Valor medio cuadrático	18	120	Valor medio cuadrático	18	120
		PR de alfa			PR de alfa		
		PR e beta			PR e beta		
		PR de delta			PR de delta		
		PR de gamma			PR de gamma		
		PR de theta			PR de theta		

Tabla 6. Parámetros de los modelos según el dominio y el tipo de clasificación.
PR: Potencia Relativa.

3.3. Modelos de aprendizaje automático

A cada uno de los grupos se le realizaron tres diferentes técnicas de aprendizaje automático, las cuales fueron las mismas para los tres diferentes casos: Máquina de soporte vectorial, Knn fino, y árboles de decisión con técnica de *bagging*. Las especificaciones para cada uno de los algoritmos se pueden ver a continuación.

Knn Fino:

- Distancia: Euclidiana
- Número de vecinos usados: 1
- Peso de distancia: No
- Tipo de vecino: Más cercano
- Ruptura de empate (en caso de que exista): Índice más pequeño.

Si se realiza un Knn fino se asume que la clasificación será por el vecino más cercano a la muestra, y además que el número de vecinos K, será igual a 1. Por otra parte, la distancia con la cual se mide la distancia entre muestras es la euclidiana, ya que es una de las más comúnmente usadas para los algoritmos de clasificación Knn [44]. En caso de que exista un empate entre las distancias a los grupos más cercanos a la muestra, la clasificación se realizará según el grupo con menor índice.

Árbol de decisión por bagging:

- Método: Agregación por bootstrapping
- Número de clasificadores: 30
- Splits: 2880
- Ciclos de aprendizaje: 30

Al momento de realizar la clasificación por medio de árboles de decisión se probaron diferentes modelos con el fin de observar cuál de ellos presentaba mejores resultados para la presente investigación. Por lo cual, los parámetros escogidos fueron seleccionados a partir de la evaluación y comparación de diferentes modelos con parámetros similares. Sin embargo, el hecho de utilizar árboles con técnica de bagging, se debe a que en el trabajo de (Batres-Mendoza, Ibarra-Manzano, Guerra-Hernández, Almanza-Ojeda, & Montoro-Sanjosed, 2017) se empleó esta técnica, obteniendo resultados prometedores superiores al 82% [45].

Support Vector Machine:

- Función del Kernel: Polinomial
- Orden del Kernel: 3
- Box Constraint: 1
- Método de comparaciones: Uno vs. uno
- Función binaria de pérdida: Modo visagra

A la hora de seleccionar qué tipo de SVM se emplearía en el proyecto se elaboraron diferentes modelos con el fin de determinar cuál de todos sería el más apropiado para la

clasificación. Los mejores modelos tenían una característica en común: su kernel era de tipo polinomial grado 3; en otras palabras, todos sus kernels eran cúbicos, sin embargo, al realizar una comparación uno vs. uno se obtuvieron mejores resultados.

El parámetro de *'box constraint'* permite controlar el número de vectores de soporte que emplea la SVM, sin embargo, cuando el número de vectores de soporte es mayor, el algoritmo tarda más tiempo en realizar la clasificación. Tener un mayor número de vectores de soporte permite controlar la penalización en caso de que se viole el margen de separación entre clases.

Con el fin de validar los diferentes algoritmos de aprendizaje automático se utilizó la técnica de validación cruzada para cada uno de los sujetos, ya que es una manera válida de optimizar los parámetros del modelo ajustándolos lo mejor que se pueda. Para la validación se utilizó un $K=5$, es decir que la totalidad de los 120 datos etiquetados fueron particionados en cinco grupos de 24 datos cada uno. Posteriormente cuatro de los cinco grupos se empleaban como datos de entrenamiento, formando un gran grupo de 96 datos, por otra parte, el grupo restante de 24 datos se empleaba como grupo de prueba. El proceso se repetía variando el grupo de prueba hasta que cada uno de los 5 grupos fuera empleado como grupo de prueba. Este proceso se puede ver más detalladamente en la figura 21.

Iteración	Número de datos por grupo					Grupos finales	
	Grupo 1 (G1)	Grupo 2 (G2)	Grupo 3 (G3)	Grupo 4 (G4)	Grupo 5 (G5)	Entrenamiento	Prueba
1	24	24	24	24	24	G1 + G2 + G3 + G4	G5
2	24	24	24	24	24	G1 + G2 + G3 + G5	G4
3	24	24	24	24	24	G1 + G2 + G4 + G5	G3
4	24	24	24	24	24	G1 + G3 + G4 + G5	G2
5	24	24	24	24	24	G2 + G3 + G4 + G5	G1

Figura 21. Datos empleados para cada una de las $K=5$ iteraciones de la validación cruzada. Color azul: Datos para entrenamiento. Color Rojo: Datos para prueba.

Tomando en cuenta que se utilizó un $K = 5$, y que los 120 datos a particionar corresponden a los 10 experimentos de cada sujeto, si se dividen los 10 experimentos en 5 grupos iguales, cada grupo se compone de 2 experimentos de 12 datos cada uno. Por lo tanto, en cada iteración se validó el algoritmo usando 8 experimentos para el entrenamiento y 2 para la validación. Finalmente, el resultado final después de las 5 iteraciones se obtiene promediando la exactitud del algoritmo en cada una de las iteraciones.

4. RESULTADOS

Como se mencionó anteriormente, se tienen cuatro diferentes matrices de características separadas en dos grupos según el dominio de las características empleadas. Por lo tanto, en la primera parte de esta sección se expondrán los resultados correspondientes a características temporales.

Temporales			
Sujeto	Fine Knn (%)	Cubic SVM (%)	Bagged Trees (%)
#1	94,66%	90,25%	75,89%
#2	93,50%	93,63%	74,55%
#3	92,09%	91,26%	74,14%
#4	93,96%	85,97%	77,28%
#5	92,13%	91,25%	78,87%
Promedio	93,26%	90,47%	76,14%
Varianza	0,000103062	0,00063033	0,000306858

Tabla 7. Exactitudes y varianzas de la clasificación de características temporales para dos clases posterior a la validación.

Como es posible observar en la tabla 7, el algoritmo con mayor tasa de exactitud es el de agrupación por Knn fino, ya que al promediar las exactitudes de clasificación para cada uno de los sujetos se obtuvo un valor de 93.26%. Así mismo, el sujeto sobre el cual la clasificación fue más acertada es el sujeto 5, ya que se observa como los mejores desempeños de cada uno de los algoritmos de clasificación, corresponden al sujeto 5.

Temporales			
Sujeto	Fine Knn (%)	Cubic SVM (%)	Bagged Trees (%)
#1	85,24%	76,00%	70,24%
#2	87,91%	84,54%	73,85%
#3	90,97%	85,00%	66,59%
#4	84,75%	73,78%	70,62%
#5	86,49%	76,94%	74,51%
Promedio	87,07%	79,25%	71,16%
Varianza	0,000499666	0,002137322	0,00080963

Tabla 8. Exactitudes y varianzas de la clasificación de características temporales para tres clases posterior a la validación.

Para la clasificación de tres clases basada en características temporales, al igual que en la clasificación bi-clase, el algoritmo de aprendizaje automático que presenta un mejor desempeño es el de agrupación fina por K vecinos más cercanos, ya que en promedio tiene una exactitud del 87.07% sobre el total de las muestras. Mientras que el peor clasificador es el árbol de decisión, con un promedio de exactitud de 71.16%.

Frecuenciales			
Sujeto	Fine Knn (%)	Cubic SVM (%)	Bagged Trees (%)
#1	98,68%	94,35%	84,31%
#2	97,08%	92,92%	80,80%
#3	98,89%	92,22%	77,82%
#4	97,60%	88,65%	82,08%
#5	98,33%	96,94%	84,29%
Promedio	98,11%	93,01%	81,86%
Varianza	0,000045	0,000737856	0,00058802

Tabla 9. Exactitudes y varianzas de la clasificación de características frecuenciales para dos clases posterior a la validación.

Como en casos anteriores, se observa que el algoritmo de clasificación más apropiado para realizar la clasificación es el de agrupación fina por K vecinos más cercanos, ya que obtiene resultados prometedores, teniendo en cuenta su eficacia promedio de 98.116%.

Frecuenciales			
Sujeto	Fine Knn (%)	Cubic SVM (%)	Bagged Trees (%)
#1	89,24%	84,24%	74,24%
#2	91,25%	88,30%	73,74%
#3	93,13%	86,91%	68,54%
#4	88,37%	79,97%	71,91%
#5	89,55%	89,13%	76,87%
Promedio	90,31%	85,71%	73,06%
Varianza	0,000286442	0,00109906	0,000762476

Tabla 10. Exactitudes y varianzas de la clasificación de características frecuenciales para tres clases posterior a la validación.

Nuevamente, el algoritmo con mejor desempeño es el de agrupación, mientras que el de peor desempeño es el árbol de decisión. Con el fin de analizar de mejor manera las varianzas de los algoritmos, se propone en la figura 22.

Con el fin de observar de mejor manera los resultados de exactitud en cada algoritmo, en la tabla 11 se expone el promedio de exactitud a lo largo de todos los sujetos para cada una de las clasificaciones planteadas.

	Fine Knn	Cubic SVM	Bagged Trees
Frecuencia (Dos clases)	98,12%	93,02%	81,86%
Tiempo (Dos clases)	93,27%	90,47%	76,15%
Frecuencia (Tres clases)	90,31%	85,71%	73,06%
Tiempo (Tres clases)	87,07%	79,25%	71,16%

Tabla 11. Desempeño promedio de cada algoritmo según la clasificación realizada.

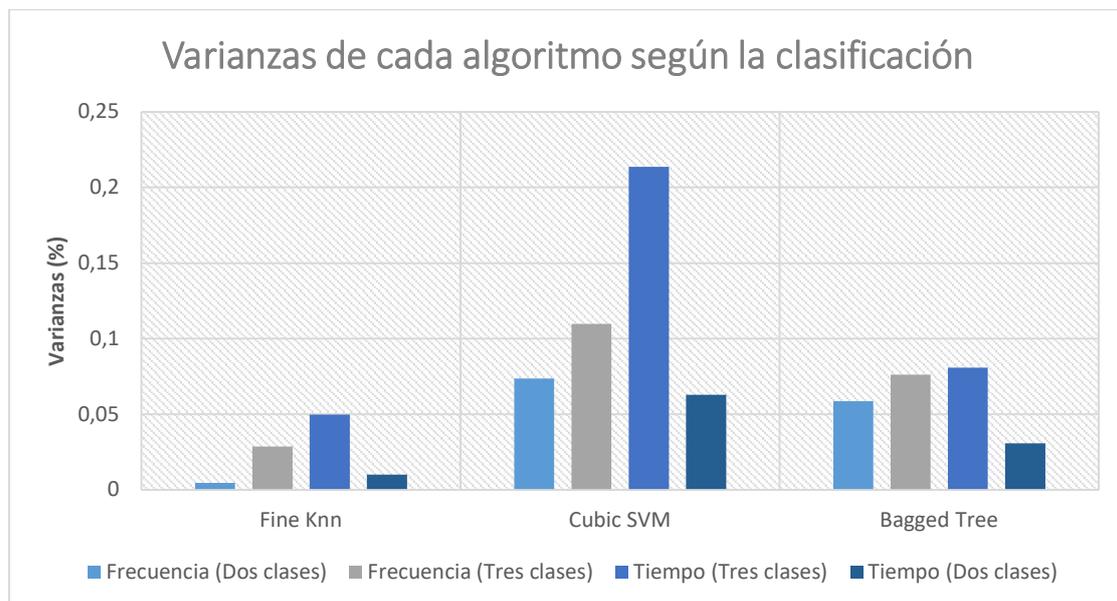


Figura 22. Varianza de cada algoritmo según la clasificación realizada.

Para cada uno de los algoritmos de aprendizaje automático se calculó la matriz de confusión basado en las respuestas predichas por el algoritmo, y a las respuestas conocidas, las cuales fueron las etiquetas cada medio segundo previamente. Algunas de las matrices de confusión con mejores resultados se pueden apreciar en los anexos del documento, sin embargo, se presentarán en esta sección algunas de estas matrices, con el fin de proporcionar información suficiente para generar un análisis adecuado, y comparar los métodos de una mejor manera.

		Frecuencia (Tres clases) Knn		
Clase real	1	89,44%	1,11%	9,44%
	0	1,54%	95,24%	3,22%
	-1	7,40%	9,59%	83,01%
		1	0	-1
		Clase predicha		

Tabla 12. Matriz de confusión para la clasificación de tres clases, basada en características frecuenciales y la agrupación fina por K vecinos más cercanos para el sujeto 4.

		Frecuencia (Dos clases) SVM	
Clase real	1	92,18%	7,82%
	0	8,29%	91,71%
		1	0
		Clase predicha	

Tabla 13. Matriz de confusión para la clasificación binaria, basada en características frecuenciales y máquinas de soporte vectorial para el sujeto 2.

A la hora de realizar la clasificación, los desempeños mejoran si se emplean características frecuenciales, por lo tanto, se propone la tabla 14 con el fin de exponer el porcentaje de mejora para cada tipo de algoritmo.

	Dos Clases			Tres Clases		
	Temporales	Frecuenciales	Mejora	Temporales	Frecuenciales	Mejora
Fine Knn	93,26%	98,11%	4,85%	87,07%	90,31%	3,24%
Cubic SVM	90,47%	93,01%	2,54%	79,25%	85,71%	6,46%
Bagged Trees	76,14%	81,86%	5,72%	71,16%	73,06%	1,90%
Promedio			4,37%			3,87%

Tabla 14. Desempeño promedio de los algoritmos, y porcentaje de mejora, de acuerdo con el cambio en el grupo de características empleado para clasificación biclase y multiclase.

5. DISCUSIÓN

En la tabla 7 se evidencia que el algoritmo de aprendizaje automático bi-clase basado en características temporales más efectivo, es el de Knn fino con una exactitud promedio de 93,26%, seguido por la SVM con una exactitud de 90,47%, y finalmente, el algoritmo que presentó peor desempeño fue el árbol de decisión con técnica de *bagging*, obteniendo una exactitud promedio para los cinco sujetos de 76,14%. Por otra parte, cuando la clasificación pasa de ser bi-clase a multi-clase, el desempeño de los algoritmos disminuye. Esto se evidencia en la tabla 8, ya que el algoritmo Knn obtuvo una exactitud de 87.07%, la SVM de 79.25%, y los árboles de decisión de 71.16%.

Esto cobra sentido cuando se comprende que al aumentar en una opción las alternativas para la clasificación, los algoritmos de clasificación adquieren una mayor complejidad. Por ejemplo, para una SVM multi clase se deben realizar un número de SVMs igual al número de clases existan, para posteriormente computar los resultados de cada SVM de clases sintéticas. Esto implica un mayor costo computacional, ya que se deben realizar tres diferentes *kernels* de decisión, lo que puede implicar un mayor error a la hora de clasificar las nuevas muestras.

A pesar de que en la clasificación dada por características extraídas en el dominio de la frecuencia en el caso bi-clase por árboles de decisión se obtuvieron exactitudes inferiores al resto de los algoritmos de clasificación, las características frecuenciales arrojaron resultados muy positivos si los comparamos con estudios como el de (Mdisa, Amir, Ilyas, & Razalli, 2017) [19]. Ya que, empleando el algoritmo de clasificación por K vecinos más cercanos y características frecuenciales, obtuvieron una exactitud promedio de 77.53% para la clasificación de intención de movimiento de mano izquierda y derecha. De igual manera, compararon el algoritmo de Knn con una SVM que tiene una exactitud promedio de 78.22% para realizar la misma clasificación. Comparando las exactitudes del estudio mencionado con los de la presente investigación, las exactitudes promedio de la agrupación Knn y la SVM (ver Tabla 9) mejoran en un 20.58% y un 14.79% respectivamente.

A pesar de utilizar características del mismo dominio, se evidencia una mejora significativa a la hora de clasificar la intención de movimiento. Esto se puede deber a que en el presente estudio se utilizaron tres electrodos con gran cercanía a la corteza primaria motora [41], mientras que en el de (Mdisa, Amir, Ilyas, & Razalli, 2017) se emplearon once electrodos distribuidos a lo largo del lóbulo central y frontal, lo que puede llevar a la redundancia de datos ya que se puede llegar a analizar incluso características innecesarias, que pueden implicar un sobreajuste de los datos [19].

Si se comparan los resultados de exactitud obtenidos en las tablas 9 y 10 es posible observar que se produce el mismo comportamiento que en las clasificaciones basadas en características temporales. De igual manera, a la hora de existir una nueva clase, el algoritmo es más complejo, pudiendo inducir un error mayor a la hora de realizar la clasificación. Adicionalmente, al ubicar espacialmente los electrodos C3, CZ, y C4 en el sistema internacional 10-20 (ver Figura 7) se observa como C3 y C4 se ubican equidistantes a la línea vertical central en donde se encuentra Cz. Sin embargo, a pesar de ser cercanos a la corteza primaria motora, la distancia de separación entre Cz respecto a C3, y C4 puede ser corta para lograr diferenciar de una manera más efectiva las características que produce cada lóbulo a la hora de distinguir entre la intención de movimiento de mano derecha

(hemisferio izquierdo → C3) o intención de movimiento de mano izquierda (hemisferio derecho → C4). Además, un sistema de clasificación con señales de EEG es muy susceptible a los cambios en la entrada, por lo que un pequeño error en el posicionamiento de los electrodos puede inducir un error a la hora de clasificar los datos.

Revisando la precisión de cada una de las clasificaciones en una matriz de confusión, es posible determinar qué miembro fue más fácil de identificar para el algoritmo. Por ejemplo, en la tabla 12 la segunda fila corresponde a la identificación de relajación. Por lo que se tiene que para dicha clasificación el 95.24% del 100% de los datos fueron clasificados en la clase correcta. Mientras que el 1.54% de los datos se clasificó como imaginación de movimiento en mano derecha, y el 3.22% como imaginación de movimiento en mano izquierda. Además, la fila 1 (Correspondiente a clasificación de mano derecha) indica que el 89.44% de los datos se clasificaron correctamente, mientras que el 9.44% fue clasificado como movimiento imaginario de mano izquierda, y el 1.11% como relajación. Por lo tanto, en dicha clasificación es más complicado determinar si el sujeto imagina movimiento de mano izquierda. Esto se corrobora al analizar la tercera fila, ya que solo un 83.01% de los datos se clasificaron como deberían, y el 9.59% se clasificó como relajación.

Este tipo de comportamiento se ve a lo largo de las pruebas (ver Anexos), en dónde en casi la totalidad de los casos se clasifica de mejor manera la imaginación de movimiento en mano derecha. La razón puede ser que los sujetos posiblemente manifiestan información más relevante relacionada a su lóbulo dominante, ya que el fenotipo de los seres humanos determina si una persona manipula de manera más sencilla su mano izquierda (zurdo) o derecha (diestro), por lo que utilizar preferentemente una mano sobre la otra para desarrollar acciones cotidianas implica que el cerebro optimiza dichas acciones [46], lo que podría manifestarse en el registro de señales EEG del lóbulo dominante, permitiendo obtener una mejor clasificación de la mano dominante.

Por otra parte, la tabla 11 permite distinguir qué métodos son más apropiados para clasificar la intención de movimiento en miembro superior. Allí se observa cómo se produce un comportamiento similar en todos los desempeños, indiferente al tipo de características y número de clases empleado. Por lo tanto, se puede decir que el mejor método para clasificar intención de movimiento en el presente estudio es el de agrupación por K vecinos más cercanos, seguido por la SVM cúbica, y finalmente, el peor algoritmo de clasificación en todos los casos es el de árboles de decisión por método de *bagging*, superando apenas en un caso el 73.06% de exactitud promedio.

A pesar de que en estudios con propósitos similares al actual se suelen usar máquinas de soporte vectorial para clasificar la intención de movimiento, se demuestra que el uso del algoritmo de clasificación por Knn fino presenta resultados comparables, e incluso mejores para realizar dicha clasificación. Esto cobra bastante importancia, ya que como se mencionó en repetidas ocasiones, las máquinas de soporte vectorial tienden a adquirir mayor complejidad a medida que se requieren clasificar más de dos clases, lo que afecta también al tiempo de ejecución del algoritmo. Y, al ser la agrupación por Knn uno de los algoritmos de aprendizaje automático más básicos, los gastos computacionales no son comparables a los de una SVM multiclase [19].

La varianza de acuerdo con los desempeños de clasificación para los cinco sujetos aumentó a medida que la complejidad matemática del algoritmo de clasificación también

aumentó. (ver Figura 22). Por lo tanto, si se evalúa únicamente la varianza entre sujetos, el algoritmo de agrupación por Knn es superior respecto a los demás (árbol de decisión y SVM), indiferente al grupo de características empleado y al número de clases existentes. Es decir, que el algoritmo que realiza una mejor generalización es el de agrupación por Knn.

Sin embargo, esto no implica que en todos los casos sea recomendable hacer la clasificación de movimiento imaginario bajo un algoritmo de complejidad baja antes que con uno de mayor complejidad, ya que, el hacer uso de etapas de procesamiento más robustas, o incluso añadir una etapa de selección de características, se promueve el mejoramiento de desempeño en los algoritmos de clasificación [47], lo que implica una varianza menor, ya que al eliminar las características innecesarias, se reduce la probabilidad de tomar decisiones basadas en ruido, promoviendo un mejor desempeño del algoritmo. Por lo tanto, al mejorarse el desempeño del modelo, todas las clasificaciones serán basadas en las características primordiales, obviando ruido que hace variar la exactitud en la clasificación de un sujeto a otro, ya que no se toman características innecesarias. Sin embargo, en estudios como en el de (Munson & Caruana, 2009) se demostró que el hacer uso de una etapa de selección de características con el fin de determinar qué características son más necesarias que otras, pueden entorpecer el proceso de clasificación, por lo que le otorgan a la selección de características una función de regularización de modelos, en lugar de un método para distinguir entre entradas relevantes e irrelevantes [48].

Por lo tanto, determinar información exacta sobre en qué momentos es mejor hacer uso de un tipo de algoritmo u otro es algo complicado, ya que, al existir una amplia gama de posibilidades a la hora de adquirir los datos, pre – procesarlos, procesarlos, seleccionarlos, y clasificarlos, los resultados de diferentes estudios pueden converger, contradecirse, o incluso ambas.

Como se puede observar a lo largo de la sección de resultados, y más específicamente en la tabla 14, los algoritmos suelen presentar una mejor clasificación cuando a las señales de EEG le son extraídas características frecuenciales. Este comportamiento se da tanto para la clasificación bi clase, como para la clasificación multi clase a lo largo de todas las pruebas realizadas. Este resultado es de esperarse, ya que cuando se tiene el espectro de las señales es posible calcular de manera simple las potencias relativas por banda, lo que brinda información relacionada con diferentes procesos cognitivos como sueño, estrés, relajación, concentración, comunicación, o intención de movimiento. Esta última es perceptible únicamente en la región sensomotora del cerebro, en la corteza primaria motora en un ancho de banda de 7 – 13 Hz. Por lo tanto, es coherente que al estar registrando de manera constante las potencias relativas de cada banda de EEG producidas en posiciones cercanas a la corteza primaria motora, se obtenga la información suficiente para poder llegar a resultados muy positivos sobre la planeación de movimiento, como sucede en estudios como los de (Zarjam, Epps, & Chen, 2011), (Triana, Orjuela-Cañón, & Jutinico, 2019), (Reyes, 2013) y el actual [42] [18] [22].

Por otra parte, debido a que las bandas de frecuencia analizadas contienen información específica con respecto a la tarea cognitiva que se está desempeñando, se creía que realizar la clasificación con características frecuenciales brindaría resultados muy superiores a la clasificación basada en características temporales. Sin embargo, al realizar el análisis de las señales cada 0.5s es probable que se tome información importante debido a las características temporales extraídas que permitan diferenciar entre cuando se presenta

un ritmo sensomotor. Ya que como se observa en la figura 9, el tiempo aproximado en el que se producen los ritmos sensomotores es de 0.5s para la desincronización, y de 0.5s para la sincronización. Esto se corrobora a la hora de revisar estudios como el de (Zhao & Zhang, 2007), en el cual obtienen resultados que confirman que hacer uso de características temporales refleja los potenciales relacionados a eventos como ERS y ERD, los cuales pueden ser útiles para la clasificación de tareas cognitivas como la imaginación de movimiento [49]. Además, sugieren que el gran problema de realizar una clasificación con características frecuenciales es que no se tiene información con respecto al tiempo en el que ocurren los potenciales relacionados a eventos, por lo que proponen el desarrollo de una clasificación que involucre ambos dominios (tiempo y frecuencia), y que emplee una etapa de selección de características para emplear solo las más efectivas.

Como se comentó anteriormente, la base de datos utilizada para el estudio actual también fue empleada en el estudio de (Triana, Orjuela-Cañón, & Jutinico, 2019) para clasificar la intención de movimiento de miembro superior en un sujeto empleando redes neuronales con perceptrón multicapa y *back-propagation* [18]. Para la clasificación fueron empleadas ventanas de tiempo de 3s, y las potencias relativas de alfa y beta en los mismos canales de EEG empleados en el actual estudio. A pesar de no poder comparar las varianzas debido a que entrenaron el modelo únicamente con un sujeto, los resultados de exactitud muestran que, para la base de datos empleada, el uso de una ventana de tiempo de menor duración, e incluir como características como el valor RMS, y las demás potencias relativas brinda mejoras significativas respecto al desempeño de la clasificación. Ya que la exactitud promedio obtenida de 68% es inferior a todas las exactitudes promedio de clasificación multi clase del actual estudio, llegando a superarla incluso en un 22.31% para el caso de agrupación por Knn. Además, incluso empleando características temporales los resultados son significativamente superiores haciendo uso del algoritmo de agrupación por Knn. Contrario es el caso de los árboles de decisión con técnica de *bagging*, cuya exactitud promedio de 73.06% es similar y comparable a la del estudio mencionado.

6. RECOMENDACIONES Y TRABAJOS FUTUROS

A pesar de obtener resultados prometedores empleando ambos grupos de características por separado (tiempo y frecuencia), se recomienda emplear características de ambos dominios para la etapa de procesamiento, ya que, al mantener la información frecuencial respecto a la tarea cognitiva desempeñada, y al mismo tiempo, la información sobre potenciales relacionados a eventos es probable que el desempeño de la clasificación aumente.

Realizar el estudio sobre un grupo de personas más amplio con el fin de obtener una aproximación más acertada a cerca de la generalización del algoritmo. Así mismo, el uso de un mayor número de electrodos relacionados con la corteza primaria motora podría proveer más información relevante para llevar a cabo el proceso de clasificación.

Por otra parte, la clasificación de intención de movimiento puede ser implementada en dispositivos de asistencia para personas con tetraplejía completa, en el cual el sujeto sea capaz de controlar el movimiento de un vehículo que le proporcione movilidad. A pesar de que con la clasificación realizada se podrían controlar tres movimientos de dicho vehículo, realizar una clasificación de un mayor número de movimientos o tareas cognitivas podrían brindar mayor libertad al usuario para poder manipular el dispositivo, lo cual beneficiaría su calidad de vida.

Existen diferentes estudios en los cuales trabajar con metodologías y bases de datos similares, arrojan resultados contradictorios; esto se debe a que existe una amplia gama de opciones a la hora de adecuar, procesar, y clasificar las señales de EEG. Por lo tanto, la creación de parámetros, o reglamentaciones relacionadas con cada una de las etapas serían de gran ayuda si se deseara implementar dicha tecnología en diferentes dispositivos asistenciales para su producción en masa, ya que se tendría una serie de estipulaciones que permitan obtener los mejores resultados de clasificación.

7. CONCLUSIONES

Clasificar la intención de movimiento de una persona en señales de EEG es una tarea compleja, y más aún cuando se requiere diferenciar el lado izquierdo y derecho del cuerpo. Para llevar a cabo dicha tarea existen diferentes métodos que pueden ser aplicados según sea la necesidad y el propósito de la clasificación. Si los resultados actuales son comparados con otros estudios de propósitos similares, es claro cómo se logró mejorar el desempeño de la clasificación de imaginación de movimiento, por medio del uso de técnicas de aprendizaje automático como: agrupación por K vecinos más cercanos, máquinas de soporte vectorial (SVM), y árboles de decisión.

Se logró clasificar la intención de movimiento de mano izquierda y derecha, gracias a una base de datos creada a partir de 5 sujetos sanos, sobre la cual se realizó un estudio similar obteniendo resultados prometedores. Sin embargo, el actual estudio mejoró la clasificación de dicho estudio en hasta un 20%, llegando a obtener exactitudes de clasificación incluso de 98,89% para la clasificación biclase, y de 93,13% para la clasificación multiclase.

En el presente estudio, la complejidad matemática de los algoritmos de clasificación empleados fue determinante para sus desempeños, ya que el uso de un algoritmo de baja complejidad matemática como la agrupación por Knn presentó mejores resultados en cuanto a desempeño y generalización, que algoritmos como las SVMs y los árboles de decisión. Así mismo, el tamaño de la ventana utilizado para analizar la grabación fue fundamental para mejorar los resultados de clasificación existentes en otros estudios.

El uso de características frecuenciales obtuvo mejor desempeño tanto en clasificación multi clase, como en clasificación bi clase, debido a que son las características que brindan información relacionada al proceso cognitivo que se está llevando a cabo en la región sensomotora. Sin embargo, usar características temporales no implica un deterioro significativo en los desempeños de los algoritmos, ya que la mejora promedio debido al uso de características frecuenciales es apenas cercana al 4% para los dos tipos de clasificación. Esto puede deberse a que cuando las ventanas de tiempo para la clasificación con características temporales son cortas, es posible que el algoritmo pueda interpretar los potenciales relacionados a eventos, ya que siempre se comportan de una manera característica, y el tiempo de sincronización y desincronización es igual al tamaño de la ventana seleccionado en el presente estudio.

Es posible que la dominancia lateral manual implique que el cerebro refleje información más útil en el lóbulo de dominancia de una persona, debido al constante uso de la mano preferente, ya que, a la hora de realizar la clasificación de imaginación de movimiento, el algoritmo clasifica de mejor manera el movimiento en una mano que en la otra.

El tamaño de la ventana, la selección de características, y las variables comprendidas dentro de la técnica de aprendizaje automático empleada, entre otros, son factores que alteran el proceso de clasificación de los algoritmos que pretenden detectar la imaginación de movimiento, ya que existen diferentes estudios, en los cuales, el uso de protocolos similares, arrojan resultados diferentes, e incluso contradictorios.

REFERENCIAS

- [1] O. Organización Mundial de la Salud, «Una Figura Global de la Lesión de Médula Espinal,» de *Perspectivas Internacionales de la Lesión de Médula Espinal*, Malta, Librería de la OMS, 2015, pp. 11-32.
- [2] B. Molina, «Estudio Neurosicológico del Deterioro Cognitivo Ligero en la Lesión de Médula Espinal,» Repositorio Universitario Institucional de la Universidad de Castilla, La Mancha, España, 2016.
- [3] J. Acevedo, L. Varón, M. Berbeo, O. Feo y R. Díaz, «Avances fisiopatológicos para el entendimiento de la lesión medular traumática.,» *Revista Colombiana de ortopedia y traumatología*, Bogotá, Colombia, 2008.
- [4] L. Bonnet, F. Lotte y A. Lécuyer, «Two Brains, One Game: Design and Evaluation of a Multiuser BCI Video Game Based on Motor Imagery,» *IEEE Transactions on Computational Intelligence and AI in Games*, vol. 5, nº 2, 2013.
- [5] N. Centro de Estadística Nacional de Lesión de Médula Espinal, «Vistazo al los Hechos y Figuras de la Lesión de Médula Espinal,» Universidad de Alabama, Birmingham, 2020.
- [6] Centro de Estadística Nacional de Lesiones de Médula Espinal, «LESIÓN DE LA MÉDULA ESPINAL: Datos y Cifras a la Vista,» Birmibnham, Alemania., 2013.
- [7] L. Semino, «Actividades de la vida diaria en pacientes con lesiones medulares,» de *III Taller Nacional Sobre Rehabilitación de Lesiones Medulares*, La Habana, Cuba, 1997.
- [8] J. Kim, H. Park, J. Bruce y D. Rowles, «The Tongue Enables Computer and Wheelchair Control for People with Spinal Cord Injury,» *Science Translational Medicine*, 2013.
- [9] B. Israel, «Georgia Institute of Technology,» 2 Diciembre 2013. [En línea]. Available: <https://www.news.gatech.edu/features/tongue-drive-wheelchair>.
- [10] M. Shibata, C. Zhang, T. Ishimatsu, M. Tanaka y J. Palomino, «Improvement of a Joystick Controller for Electric Wheelchair User vol. 5, pp. 132-138, 2015.,» *Modern Mechanical Engineering*, vol. 5, pp. 132-138, 2015.
- [11] R. Roy, A. Konar y D. Tibarewala, «Control of Artificial Limb Using EEG and EMG - A Review,» Escuela de Biosciencias e Ingenierías de la Universidad de Jadavpur, Kolkata, 2011.
- [12] S. Pulido y J. López, «Interfaz Cerebro-Máquina con base en Detección de Intención de Movimiento y Técnicas de Aprendizaje Automático,» *Encuentro Internacional de Educación en Ingeniería ACOFI*, 2017.
- [13] T. Zander, «Did you know... Brain Computer Interfaces (Part 2),» Brain Products, 2010.
- [14] M. Bamdad, H. Zarshenas y A. Mohammad, «Application of BCI systems in neurorehabilitation: a scoping review,» *Disability and Rehabilitation: Assistive Technology*, vol. 10, nº 5, pp. 355-364, 5 Enero 2015.
- [15] M. Alomari, A. Samaha y K. AlKamba, «Automated Classification of L/R Hand Movement EEG Signals using Advanced Feature Extraction and Machine Learning,» (*IJACSA*) *International Journal of Advanced Computer Science and Applications*, vol. 4, nº 6, pp. 207-212, 2013.
- [16] A. Albajes-Eizagirre, L. Dubreuil Vall, D. Ibanez-Soria, A. Riera, A. Soria-Frisch, S. Dunne y G. Ruffini, «Quantitative EEG for Brain-Computer Interfaces,» de *EEG/ERP Analysis: Methods and Applications*, Boca Ratón, FL, CRC Prensa, 2014, pp. 157-75.

- [17] P. Herrera, «Influencia de la retroalimentación visual en el control de una interfaz cerebro-computador mediante imaginación motora,» Escuela de Posgrado, Pontificia Universidad Católica del Perú, Lima, 2017.
- [18] N. Triana, Á. Orjuela-Cañón y A. Jutinico, «Incremental Training of Neural Network for Motor Tasks Recognition Based on Brain-Computer Interface,» de *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications*, La Habana, Cuba, 2019, pp. 1-10.
- [19] N. Mdisa, A. Amir, M. Ilyas y M. Razalli, «The Performance Analysis of K-Nearest Neighbors (K-NN) Algorithm for Motor Imagery Classification Based on EEG Signal,» ICEESI, Perlis, Malasia, 2017.
- [20] J. Khan, M. Bhatti, U. Khan y R. Iqbal, «Multiclass EEG motor-imagery classification with sub-band common spatial patterns,» *EURASIP: Journal on Wireless Communications and Networks*, p. 174, 2019.
- [21] M. Ochiuddin, R. Mahfuzur, M. Rafsanjani y F. Dewan, «Prediction of Motor Imagery Tasks from Multi-Channel EEG Data for Brain-Computer Interface Applications,» Bangladesh, 2020.
- [22] A. Reyes, «Interfaz Cerebro Computador Mediante la Clasificación de Señales Electroencefalográficas,» Bogotá, 2013.
- [23] J. Bernal, «¿Qué es un electroencefalograma?,» 22 Diciembre 2015. [En línea]. Available: <https://drbernalneurologo.net/2015/12/22/que-es-un-electroencefalograma/>.
- [24] J. Walpaw, «Brain-computer interfaces for communication and control,» *Clinical Neurophysiology*, pp. 602-614, 2002.
- [25] J. Andrade y A. Riascos, «Desarrollo de un prototipo de interfaz cerebro-máquina, basado en el análisis de la densidad espectral de energía de las señales electroencefalográficas con transformada Wavelet,» Facultad de Ingeniería, Universidad del Magdalena, Santa Marta, 2017.
- [26] S. Neurocoop, «Guía de atención. Electroencefalograma,» Cúcuta, 2018.
- [27] B. Kolb y I. Whishaw, Organización del Sistema Motor, Madrid: Editorial Médica Panamericana, 2006.
- [28] R. Navarro, «Instrumentación Biomédica,» Departamento de Electrónica, Universidad de Alcalá, Alcalá, 2015.
- [29] E. Batista, S. Cerracín, L. Gómez, R. Moreno y I. Moreno, «Análisis y caracterización de señales eléctricas del cerebro utilizando interfaz cerebro-computador,» Facultad de Ingeniería Eléctrica, Universidad Tecnológica de Panamá, Chiriquí, 2019.
- [30] S. Lemm, G. Curio y K.-R. Müller, «A Generalized Framework for Quantifying the Dynamics of EEG Event-Related Desynchronization,» *PLoS Comput*, vol. V, n° 8, pp. 3-13, 7 Agosto 2009.
- [31] E. Cuevas, «Máquinas de Soporte Vectorial con Algoritmos Basados en Poblaciones Para el Pronóstico del Precio de Acciones LAN Chile,» Facultad de Ingeniería, Universidad Católica de Valparaíso, Chile, 2010..
- [32] J. Fonrari, «Inteligencia Artificial y Creatividad Musical,» 12 Diciembre 2019. [En línea]. Available: <https://www.blogs.unicamp.br/musicologia/2019/12/12/40/>.
- [33] Y. Liu, «Overfitting, underfitting, and the bias-variance tradeoff,» de *Python Machine Learning by Example*, Birmingham, Packt Publishing, 2017, pp. 14-17.

- [34] E. Vidal y F. Casacuberta, «Introducción al aprendizaje automático,» Valencia, 2019.
- [35] J. Brownlee, «Overfitting and Underfitting,» de *Master Machine Learning Algorithms: Discover How They Work and Implement Them for Scratch*, Todos los derechos reservados, 2016, pp. 23-24.
- [36] J. Ashfaq y A. Lqbal, «Introduction to Support Vector Machines and Kernel Methods,» East Kent Hospitals University NHS Foundation, Canterbury, 2019.
- [37] M. Hossin y M. Sulaiman, «A Review on Evaluation Metrics for Data Classification Evaluations,» *International Journal of Data Mining & Knowledge Management Process*, pp. 1-11, 2015.
- [38] C. Jiménez y J. Moreno, «Modelo de máquinas de soporte vectorial para la detección de fallas en bicicletas basado en acústica,» Facultad de Ingeniería, Universidad Distrital Francisco Jodé de Caldas, Bogotá, 2017.
- [39] B. Dasarthy, «. Nearest Neighbour (NN) Norms: NN Pattern Recognition Techniques,» IEEE Community Society Press, 1991.
- [40] S. Salzberg y S. Cost, «A weighted nearest neighbour algorithm for learning with symbolic features,» *Machine Learning*, vol. 10, nº 1, 1993.
- [41] Y. Wang, B. Hong, X. Gao y S. Gao, «Design of electrode layout for motor imagery based brain-computer interface,» *Electronic Letters*, vol. 43, nº 10, 10 Mayo 2007.
- [42] P. Zarjam, J. Epps y F. Chen, «Spectral EEG Features for Evaluating Cognitive Load,» de *33rd Annual International Conference of the IEEE EMBS*, Boston, 2011.
- [43] C. Vidaurre, C. Krämer, B. Blankertz y A. Schlögl, «Time Domain Parameters as a feature for EEG-based Brain-Computer Interfaces,» *Neural Networks*, nº Edición Especial 2009, pp. 1313-1319, 16 Julio 2009.
- [44] L. Hu, M. Huang, S. Ke y C. Tsai, «The distance function effect on k-nearest neighbor classification for medical datasets,» *Springerplus*, vol. 1, nº 5, 2016.
- [45] P. Batres-Mendoza, M. Ibarra-Manzano, E. Guerra-Hernández, D. Almanza-Ojeda y C. R.-T. R. R.-G. H. Montoro-Sanjosed, «Improving EEG-based motor imagery classification for real time applications using the QSA method,» *Computational intelligence and neuroscience*, 2017.
- [46] M. Gómez, «El Niño Zurdo,» de *Trastornos del Neurodesarrollo y Aprendizaje*, Bogotá, 1999, pp. 116-121.
- [47] A. Gupta, R. Agrawal y B. Kaur, «Performance enhancement of mental task classification using EEG signal: a study of multivariate feature selection methods.,» *Soft Computing*, vol. 10, nº 19, pp. 2799-2812, 2014.
- [48] M. Munson y R. Caruana, «On Feature Selection, Bias-Variance, and Bagging,» pp. 144-159., 2009.
- [49] Q. Zhao y L. Zhang, «Temporal and spatial features of single-trial EEG for brain-computer interface,» *Computational intelligence and neuroscience*, pp. 376-95, 2007.
- [50] J. P. Claudia Henao, «Spinal Cord Injuries and Disabilities: A Review,» Aquichan, Colombia, 2010.
- [51] S. Guan, K. Zhao y S. Yang, «Motor Imagery EEG Classification Based on Decision Tree Framework and Riemannian Geometry,» *Computational Intelligence and Neuroscience*, pp. 1-13, 2019.

ANEXOS

Matrices de confusión para la clasificación de tres clases, basada en características frecuenciales del sujeto 4.

		Frecuencia (Tres clases) Knn					Frecuencia (Tres clases) SVM					Frecuencia (Tres clases) Bagged		
Clase real	1	89,44 %	1,11%	9,44%	Clase real	1	90,91 %	3,52%	5,57%	Clase real	1	88,79 %	2,59%	8,62%
	0	1,54%	95,24 %	3,22%		0	1,43%	94,43 %	4,14%		0	4,04%	85,05 %	10,91 %
	-1	7,40%	9,59%	83,01 %		-1	10,03 %	11,78 %	78,20 %		-1	6,52%	6,16%	87,32 %
		1	0	-1			1	0	-1			1	0	-1
		Clase predicha					Clase predicha					Clase predicha		

Matrices de confusión para la clasificación de tres clases, basada en características temporales para el sujeto 3.

		Tiempo (Tres clases) Knn					Tiempo (Tres clases) SVM					Tiempo (Tres clases) Bagged Trees		
Clase real	1	76,95 %	11,38 %	11,68 %	Clase real	1	72,88 %	13,07 %	14,05 %	Clase real	1	78,55 %	7,27%	14,19 %
	0	6,50%	86,45 %	7,05%		0	9,32%	81,89 %	8,79%		0	10,92 %	75,75 %	13,33 %
	-1	14,62 %	14,88 %	70,50 %		-1	17,74 %	15,05 %	67,20 %		-1	13,52 %	14,23 %	72,24 %
		1	0	-1			1	0	-1			1	0	-1
		Clase predicha					Clase predicha					Clase predicha		

Matrices de confusión para la clasificación de tres clases, basada en características frecuenciales para el sujeto 5.

		Tiempo (Tres clases) Knn					Tiempo (Tres clases) SVM					Tiempo (Tres clases) Bagged Trees		
Clase real	1	85,95 %	7,83%	3,22%	Clase real	1	80,45 %	13,05 %	6,5%	Clase real	1	79,47 %	11,9%	8,63%
	0	6,50%	86,45 %	7,05%		0	7,36%	86,90 %	5,74%		0	8,92%	73,15 %	17,93 %
	-1	10,8%	16,8%	72,40 %		-1	15,61 %	15,34 %	69,05 %		-1	11,87 %	14,21 %	73,92 %
		1	0	-1			1	0	-1			1	0	-1
		Clase predicha					Clase predicha					Clase predicha		

Matrices de confusión para la clasificación binaria, basada en características frecuenciales.

		Frecuencia (Dos clases) Knn				Frecuencia (Dos clases) SVM				Frecuencia (Dos clases) Bagged	
Clase real	1	92,18%	7,82%	Clase real	1	91,99%	8,01%	Clase real	1	85,92%	14,08%
	0	8,29%	91,71%		0	7,54%	92,46%		0	8,26%	91,74%
		1	0			1	0			1	0
		Clase predicha				Clase predicha				Clase predicha	

Matrices de confusión para la clasificación binaria, basada en características temporales.

		Tiempo (Dos clases) Knn				Tiempo (Dos clases) SVM				Tiempo (Dos clases) Bagged	
Clase real	1	90,95%	9,05%	Clase real	1	90,71%	9,29%	Clase real	1	84,72%	15,28%
	0	10,50%	89,50%		0	9,18%	90,82%		0	11,31%	88,69%
		1	0			1	0			1	0
		Clase predicha				Clase predicha				Clase predicha	