



UNIVERSIDAD CATÓLICA
SILVA HENRÍQUEZ

Facultad Ciencias de la Salud

Escuela de Kinesiología

ENTRENAMIENTO DE MÁQUINAS CLASIFICADORAS PARA LA
CORRECTA DIFERENCIACIÓN DE IMAGINERÍA MOTORA A
TRAVÉS DE UN ELECTROENCEFALÓGRAFO DE BAJO COSTO
EN POBLACIÓN NORMAL DE LA UCSH

OPTANDO AL TÍTULO:

LICENCIADO EN KINESIOLOGÍA

AUTORES:

Manuel Fernández, Cristián González

PROFESOR GUÍA:

Cristian Riveros

Santiago, Chile, 2017

ENTRENAMIENTO DE MÁQUINAS CLASIFICADORAS PARA LA
CORRECTA DIFERENCIACIÓN DE IMAGINERÍA MOTORA A
TRAVÉS DE UN ELECTROENCEFALÓGRAFO DE BAJO COSTO
EN POBLACIÓN NORMAL DE LA UCSH

Cristian Riveros Matthey

Kinesiólogo

Profesor Guía

Profesor Corrector

Profesor Corrector

Santiago, Chile 2017

AUTORIZACION PARA FINES ACADEMICOS

SE AUTORIZA LA REPRODUCCION TOTAL O PARCIAL, CON FINES ACADEMICOS, POR CUALQUIER MEDIO O PROCEDIMIENTO, INCLUYENDO CITA BIBLIOGRAFICA DEL DOCUMENTO.

FECHA

FIRMA

DIRECCION

TELEFONO – EMAIL:



UNIVERSIDAD CATÓLICA
SILVA HENRÍQUEZ

Facultad Ciencias de la Salud Escuela de Kinesiología

CALIFICACIONES

Firma: _____

Calificación: _____

Profesor Guía

Cristian Riveros Matthey

Firma: _____

Calificación: _____

Profesor Corrector 1

Firma: _____

Calificación: _____

Profesor Corrector 2

DEDICATORIA

Dedico esta tesis a quienes me apoyaron incondicionalmente en esta etapa de la vida, tanto en lo emocional, económico, y actitudinal.

A mis padres Juan Ramón y Claudia Mariela, por su constante esfuerzo en apoyarnos a mí y mis hermanos y darnos lo mejor.

A mi novia Josseline, por alentarme cuando parecía que me iba a rendir.

A mis profesores quienes nunca desistieron al enseñarme.

Cristián González Ibarra

Dedico esta tesis a mi madre, la principal responsable de mis logros la persona quien más amo de este mundo, a mi hijo, quien me inspira desde el día que llego a mi vida, mi novia, quien me apoya incondicionalmente en todo, a mi tía, quien me ha dado mucho, mis hermanas, pilares fundamentales en todo, a mi cuñado, a mis primos, mis padrinos y mis amigos, personas ejemplares, a todos ellos, que han sido parte del desarrollo humano, moral, personal. Pero en especial a mi tata que me cuida desde el cielo, que me hubiese encantado tenerlo al lado mío para dedicarle este proceso de vida tan lindo, a todos y cada uno de ellos muchas gracias.

Manuel Fernández Sánchez.

AGRADECIMIENTOS

Agradecemos por guiarnos en este proceso, por enseñarnos algo más de la vida, a nuestro profesor guía Cristian Riveros Matthey, quien ha estado con nosotros desde el primer día de este proyecto, a la universidad católica Silva Henríquez, por educarnos como seres pensantes, críticos de nuestro entornos y a nuestras familias, que nos han dado todo para poder llegar a estas instancias. Muchas gracias

Tabla de Contenidos

Tabla de Contenidos.....	7
Resumen.....	9
1. Introducción.....	10
2. Pregunta de Investigación	11
3. Objetivos.....	12
3.1 Objetivo General:	12
3.2 Objetivos específicos:	12
4. Marco Teórico.....	13
4.1 Electroencefalografía (EEG)	13
4.1.1 EEG-Emotiv EPOC.....	14
4.2 Tipos de imaginaria	16
4.3 Sistema de clasificación supervisada (tipología de clasificadores.....	17
4.4 Arreglo de extracción de característica	18
4.5 Análisis por CSP	20
4.6 Selector de atributos	20
4.7 Interface cerebro-computador (en su sigla en inglés BCI).....	21
5. Metodología.....	22
5.1 Tipo de estudio.....	22
5.2 Cálculo de tamaño muestral	22
5.3 Participantes y criterios de exclusión	23
5.4 Protocolo de toma de muestras.....	23
5.5 Descripción de variables.....	25
5.5.1 Variables independientes (Clasificadores)	25
5.5.2 Co Variable:	26
5.5.3 Variables dependientes:	26
5.6 Recolección de datos.....	27
5.7 Procesamiento de datos	27
5.8 Análisis estadístico	28
6. Resultados	29
Grafico 6.1	29
Tabla 6.1.1.....	30
Grafico 6.1.2.....	30
Grafico 6.1.3.....	31
Grafico 6.1.4.....	32
Grafico 6.1.5.....	33
Grafico 6.2	34

Tabla 6.2.1	34
Grafico 6.2.2	35
Grafico 6.2.3	36
Grafico 6.2.4	37
Grafico 6.3	38
Grafico 6.3.1.....	39
7. Discusión.....	40
8. Conclusión	41
9. REFERENCIAS.....	42
10. ANEXOS:.....	44
10.1 Consentimiento informado para los sujetos en la toma de muestras	44

Resumen

La lectura y naturaleza de los impulsos eléctricos provocados por el cerebro ha sido un tema de investigación ampliamente abordado desde hace mucho tiempo, sin embargo, solo durante la última década los posibles usos y beneficios de esta materia han cobrado mayor fuerza y alcance para la comunidad en general, como es el caso del neurocasco Epoc Emotiv, herramienta de bajo costo que nos permite distinguir (con un margen de error aceptable) dichas señales eléctricas y se posiciona actualmente como un fuerte candidato para la creación de una interfaz cerebro-máquina en conjunto con un buen sistema clasificador con el fin de, por ejemplo, establecer un medio de comunicación fiable para pacientes con esclerosis lateral amiotrófica. Se presenta a continuación un estudio transversal, descriptivo, observacional, de una serie de electroencefalografías manifestadas por imaginación motora y cognitiva en 21 sujetos sanos de la UCSH cuyas edades oscilan entre los 18 y 24 años, con el fin de utilizar estos datos para entrenar tres máquinas clasificadoras que deben ser capaces de señalar a qué imagen mental corresponde cada patrón, y según su grado de precisión determinar cuál de ellas está mejor capacitada para realizar este tipo de predicción, con el objetivo de disminuir el porcentaje de error al reconocer imágenes motoras que puedan ser utilizadas a futuro en un interfaz cerebro-máquina. Como resultado, el clasificador TreeJ48 sobresale obteniendo una diferencia significativa por sobre los demás, pudiendo ser utilizado sin problemas en futuras investigaciones si se replican los factores involucrados y detallados en este estudio.

1. Introducción

Hasta el día de hoy numerosos investigadores de la comunidad científica han ahondado en el estudio del área cortical y su estrecha relación con la actividad motriz desde que se descubre que generan un potencial electrofisiológico medible, siendo uno de los primeros estudios la medición de estos impulsos en animales utilizando un galvanómetro (Caton R., 1875). La investigación inicial en el campo utilizó la tecnología invasiva, uniendo los electrodos dentro del cráneo, a menudo en el cerebro mismo para leer las señales eléctricas producidas. Tales sistemas requieren cirugía para conectar los sujetos a los sensores. Las tendencias se han movido ahora hacia sistemas que hacen uso de sensores fisiológicos no invasivos como los electroencefalogramas (EEG de bajo costo y alto costo). Los sistemas EEG utilizan una serie de electrodos para leer las señales eléctricas en el cuero cabelludo causadas por la actividad cerebral (Wenjia Ouyang, 2009).

En la actualidad; a través de la imaginería motora existen diferentes formas de abordar este tema, por ejemplo, buscando alguna imagen fija ante una actividad motriz, o algún patrón en particular de forma provocada bajo la lectura de un sistema de instrumentación para captar imágenes motoras. Es mediante el desarrollo de esta línea investigativa que diversos estudios, con una máquina clasificadora, intentan predecir cuál es el patrón motor que se está ejecutando a través de una imagen motora específica para posteriormente conectarla a una respuesta física con la interface cerebro-máquina, siendo esta un sistema de conexión que permite controlar un dispositivo con la actividad neuronal, capaz de analizar y traducir estas señales adquiridas en comandos que puedan ser captados por el dispositivo de salida (JM Abullah et al., 2014).

Los instrumentos de captación son variados de baja gama y alta gama, teniendo estos últimos un alto porcentaje de reconocimiento, sobre todo cuando se trata de decodificar dos intenciones imaginadas distintas (A.A. Torres García, 2013), por otro lado, el EEG de bajo costo si bien capta señales es más propenso a contaminarse con otras señales electromiográficas y electro-oculográficas (J.J. Shih et al, 2012), siendo un desafío poder captar señales corticales con instrumentos de bajo costo al ser más accesibles para la clínica. Sin embargo, actualmente no hay un sistema contundente capaz de reconocer fielmente una imagen cortical a través de un EEG de bajo costo, y los grandes

avances sobre la BCI (*Brain Computer Interface*) son casi exclusivamente en laboratorios con elementos controlados y sujetos o animales sanos (J.J. Shih et al, 2012). Por lo tanto, es necesario comprender como un sistema construido con instrumentos de baja gama interpreta un patrón de movimiento invocado desde el sistema cortical para llevar los beneficios del estudio de esta materia desde los laboratorios (que usan equipos de mayor capacidad) a la clínica y la comunidad, pudiendo aprovechar estas señales desde la prevención a la rehabilitación y restauración en patologías neuromotrices (Sarah N. Abdulkader, 2015), por ejemplo, generando un reemplazo a futuro por una acción mecánica externa a través del BCI en caso de que falle el acto motor de un paciente.

Una de las interfaces cerebro-máquina de bajo costo más utilizada es Neurosky y EMOTIV, esta última desarrollada en 2003 para el consumo popular (Angélica Reyes, 2013) y que permite censar la actividad cerebral a través de un número limitado de electrodos, sin embargo, su principal problema radica en cómo proporcionar información rápida, precisa y fiable (McFarland DJ & Wolpaw JR, 2011), por lo que la eficacia de estos equipos se vería potenciada al resolver problemas de adquisición de señales por hardware, validación/difusión de BCI y mayormente, la confiabilidad (J.J. Shih et al, 2012). Considerando esta necesidad de manejar un patrón motor y los usos que se le pueden dar, es que este estudio tiene la intención de capturar imágenes motoras a través del electroencefalógrafo EMOTIV y utilizarlas para el aprendizaje de diferentes clasificadores del patrón motriz, con el fin de identificar aquel que tenga el mayor índice de confiabilidad y generar una línea de base en futuras investigaciones en el desarrollo de esta promesa de la tecnología médica y de ingeniería, de la que actualmente se investiga ampliamente en busca de más aplicaciones (Kamel Nidal et al, 2014).

2. Pregunta de Investigación

¿Existen diferencias entre los métodos de entrenamiento de máquinas clasificadoras para la correcta diferenciación de patrones de imaginación motora con un electroencefalógrafo de bajo costo en población normal de la UCSH?

3. Objetivos

3.1 Objetivo General:

Comparar diferentes métodos de entrenamiento de máquinas para la correcta clasificación de imaginología motora en población normal de la UCSH.

3.2 Objetivos específicos:

- Aplicar el entrenamiento y la clasificación en base a las imágenes motoras establecidas con el método 1 (Máquina clasificadora Adaboost)
- Aplicar el entrenamiento y la clasificación en base a las imágenes motoras establecidas con el método 2 (Máquina clasificadora Perceptrón multicapa)
- Aplicar el entrenamiento y la clasificación en base a las imágenes motoras establecidas con el método 3 (Máquina clasificadora TreeJ48)
- Comparar resultados según índice de confiabilidad y precisión.

4. Marco Teórico

4.1 Electroencefalografía (EEG)

Es el registro de la actividad bioeléctrica cerebral obtenido mediante electrodos situados en el cuero cabelludo o corteza cerebral (espacio subdural) (Reyes 2013).

Es una técnica de exploración funcional del sistema nervioso central (SNC) mediante la cual se obtiene el registro de la actividad eléctrica cerebral en tiempo real. En 1929 Hans Berger acuñó el término «electroencefalograma», en abreviatura EEG, para describir el registro de las fluctuaciones eléctricas en el cerebro captadas por unos electrodos fijados al cuero cabelludo (F. Ramos-Arguelles 2009).

La actividad que describe la EEG, es a través de la neuronas piramidales de la corteza cerebral, descritas en la literatura, con puntos de actividad eléctrica aumentada, tanto inhibitoria y excitatoria, dos polos que regulan su función.

La EEG realiza el estudio y análisis de los campos eléctricos cerebrales (topografía, polaridad y su variación espacial temporal) mediante la amplificación de la diferencia de potencial entre los electrodos receptores de la señal. Pueden estar situados en el cuero cabelludo (EEG estándar), en la superficie cortical (EEG cortical) o intracerebrales (EEG de profundidad).

El EEG estándar es una exploración indolora, no invasiva, de bajo coste, que puede ser de gran utilidad en la práctica clínica. Se realiza colocando electrodos de superficie adheridos al cuero cabelludo por un gel conductor. Se posicionan de acuerdo al sistema internacional 10-20 (McFarland, 2011).

Los distintos pares de electrodos se combinan constituyendo los montajes. Hay dos tipos básicos de montajes: bipolar (transversal y longitudinal) y monopolar (o referencial). El bipolar registra la diferencia de voltaje entre dos electrodos colocados en áreas de actividad cerebral, mientras que el monopolar registra la diferencia de potencial entre un electrodo ubicado en una zona cerebral activa y otro colocado sobre un área sin actividad o neutra (por ejemplo el lóbulo de la oreja); o bien, la diferencia de voltaje entre un electrodo colocado en una zona activa y el promedio de todos o algunos de los electrodos activos (Shih, 2011).

El uso de electrodos invasivos permite estudiar en detalle áreas cerebrales en ocasiones de difícil acceso como la superficie mesial del lóbulo temporal (electrodos nasofaríngeos, electrodos esfenoidales, del foramen oval, temporales anteriores, etc.).

SISTEMA INTERNACIONAL 10 – 20

Existen múltiples sistemas de posicionamiento de electrodos superficiales, sin embargo el sistema internacional 10 – 20 es el más utilizado hoy en día. Este método se desarrolló con el fin de garantizar un estándar y repetitividad de manera tal que los estudios realizados a un sujeto puedan ser comparados en el transcurso del tiempo, igualmente permite comparar los resultados entre distintos individuos (Torres García, 2013).

4.1.1 EEG-Emotiv EPOC

Es un auricular especial con electrodos inventados por la empresa de ciencia y tecnología Neural (EmotivSystems) en San Francisco y la Universidad de Essex en Reino Unido.

En la actualidad, el neurocasco Emotiv EPOC es el dispositivo de adquisición de EEG de electrodos de bajo costo más popular y se puede operar de forma sencilla. Una vez instalados los electrodos bajo el sistema internacional, Los electrodos posee un giroscopio compuesto por dos acelerómetros (ejes X y Y) los cuales registran los movimientos de la cabeza del sujeto. Se destaca la conexión entre el headset y el PC es inalámbrica (transmisor bluetooth), esa conexión hace que la toma de muestra sea muy eficaz para cualquier tipo de investigación.

Los datos se registran mediante 14 electrodos salinos más dos sensores utilizados como referencia. Las posiciones de los electrodos se describen utilizando el sistema convencional 10-20 [14]: AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, oreja son las coordenadas de ubicación correspondientes a los electrodos del dispositivo que pesquisan la señal. Emotiv EPOC tiene una frecuencia de muestreo interna de 2048Hz. Cada canal tiene una salida de 128 Hz por muestreo descendente. Los datos se transmiten a la computadora por bluetooth.

La imaginería mental es el área que abastece principalmente el uso de la EEG, Es un término que hace referencia a las representaciones mentales que dan la experiencia de percepción sin la presencia de un estímulo sensorial aferente, por lo cual podemos considerarlo un fenómeno subjetivo. Desde los años setenta, su estudio ha generado grandes controversias respecto a su existencia, su función, la forma en que se generan y las implicaciones que tienen tanto en la vida cotidiana como en las enfermedades mentales (Jhon E. Muñoz Cardona, 2014).



Dispositivo Emotiv EPOC

4.2 Tipos de imaginación

Los estudios realizados en imaginación se basan en los sistemas aferentes somáticos, principalmente visuales, auditivos, motores y olfativos, aunque posiblemente todos los sistemas aferentes hacia el sistema nervioso central (SNC) puedan recrear percepciones mentales en imaginación. Para el estudio de estas representaciones, se ha tratado de dividirlos según los canales sensoriales del que provienen, aunque pareciera que esto no se puede realizar definitivamente (N. Tamayo, 2013).

Memoria:

Nuestro cerebro funciona como un órgano de almacenamiento donde la información percibida debe ser codificada, consolidada y recobrada para su uso. En el proceso de almacenamiento, la imaginación permitiría guardar la información como memoria declarativa (Pearson DG, 2012).

Imaginación visual:

La representación visual en imaginación se ha dividido en dos componentes principales, el «qué» del objeto, que abarca todas las propiedades de este (como color, forma, tamaño, textura, etc.) y el «dónde», que hace referencia a su ubicación y manipulación espacial. Estos dos fenómenos tienen sustratos neurobiológicos diferentes y cada uno de ellos tiene submodalidades específicas (Thompson 2009). Que se debe integrar para dar la coherencia de la imagen; esto explicaría que las personas que nacen ciegas puedan realizar ejercicios de imaginación basados en ubicación espacial, pero no en características propias de los objetos.

Imaginación motora y táctil:

La imaginación motora está definida como la percepción de una acción motora sin su ejecución (Malouin, 2012). En este proceso se ha encontrado una activación de la corteza motora primaria, las cortezas motoras suplementarias, el tálamo y el cerebelo (Van der meulen M 2012), pero otros estudios no han encontrado esta correlación; tal vez tenga que ver el hecho de que un estímulo motor también puede ser representado visualmente. Estas percepciones están relacionadas directamente con la edad y características individuales del sujeto.

A través de estas imágenes abstractas se pueden generar matrices de datos procesados en softwares como MATLAB Y WEKA, este último posee los clasificadores que aportan la precisión de acuerdo a sus funciones matemáticas dadas por el tipo y calidad prestada desde el EEG (Torres García, 2013).

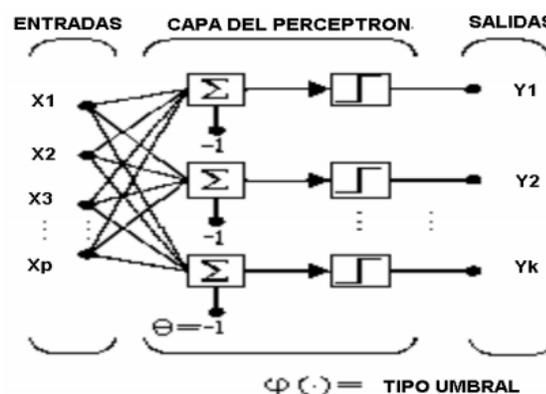
4.3 Sistema de clasificación supervisada (tipología de clasificadores)

Los patrones de actividad cerebral se consideran como procesos estocásticos debido tanto a la diversidad biológica de las señales como a los factores técnicos que rodean su proceso de adquisición.

Adaboost: Propone entrenar una serie de clasificadores débiles de manera iterativa, de modo que cada nuevo clasificador o “weak learner” se enfoque en los datos que fueron erróneamente clasificados por su predecesor, de esta manera el algoritmo se adapta y logra obtener mejores resultados (Morales, 2015).

Perceptrón Multicapa (en inglés MLP):

A partir del modelo de la neurona artificial Rosenblatt (1958, 1962) desarrollo el modelo del perceptrón el cual básicamente consiste en una capa de neuronas con pesos y umbral ajustables. Este sistema neuronal puede ser llamado una red neuronal debido a las conexiones existentes entre sus elementos (Mejiaz, 2004).



La figura grafica las posibles salidas según la capa del perceptrón que conecta con una de las entradas, aumentando la cantidad de posibles respuestas al tratarse de un clasificador no lineal.

TreeJ48: Esta técnica predictiva de clasificación consiste en una división jerárquica y secuencial del problema en el que cada una de estas divisiones o nodos describen gráficamente las decisiones posibles y por lo tanto los resultados de las distintas combinaciones de decisiones y eventos. A cada evento se le asignan probabilidades y a cada una de las ramas se le determina un resultado. Los 20 árboles representan “reglas” las que pueden ser entendidas por lo humanos con la ventaja de que el conocimiento lo genera el mismo árbol y no parte de la premisa de un experto en el tema (Dupouy, 2014).

Herramienta WEKA:

Para probar y comparar una serie de algoritmos de clasificación se usa esta herramienta, desarrollada en la Universidad de Waikato, Nueva Zelanda, escrita en formato Java (Witten, y otros, 2000). En Weka se aplicaron métodos de aprendizaje a las bases de datos donors y acceptors, y se analizaron las salidas para extraer información sobre los datos.

4.4 Arreglo de extracción de característica

En la etapa de procesamiento de una señal es fundamental realizar, en algún momento, un reconocimiento de patrones. Aquí un patrón es una descripción estructural o cuantitativa de un objeto o de alguna otra entidad de interés en una señal y está formado por uno o más descriptores. En otras palabras, un patrón es una disposición de descriptores o características. La observación de tareas particulares (como imaginarse el movimiento de la mano) genera en los sistemas BCI un particular efecto específico en las señales cerebrales medidas en una ubicación en particular. Aunque estos fenómenos cognitivos han sido ampliamente estudiados y a pesar que para la aplicación BCI se considere una sola posible señal fisiológica; la imaginación, las tareas, las mejores frecuencias y las mejores localizaciones tendrán que ser seleccionadas para cada individuo. Esta aleatoriedad entre las señales es uno de los aspectos que más limitan el procesamiento de las señales de EEG.

Las variaciones de las propiedades de la señal sobre el tiempo (frecuencia e intensidad de esta), es decir, las no estacionarias, pueden surgir de muchas fuentes y tienen diferentes escalas de tiempo, por ejemplo cambios en la

impedancia ocurren cuando un electrodo pierde el contacto con la piel o la conducción se deteriora, la actividad muscular o los movimientos de los ojos producen cambios en la señal y a menudo se observa un decremento en la atención a la tarea propuesta y se generan cambios en la actividad de fondo por fatiga o cansancio y falta de concentración. Adicionalmente cambios en la señal del EEG registrado pueden ser causados por diferencias entre sesiones, falta de realimentación en las sesiones de calibración o pequeñas diferencias entre las posiciones de los electrodos entre sesiones.

Los resultados de todas estas variaciones son una distribución de características o un vector de características que cambia con el tiempo. Una potente y muy usada técnica para el procesamiento y la extracción de características de las señales EEG para sistemas BCI es la de Patrones Espaciales Comunes (CSP por sus siglas en inglés). A lo largo del desarrollo de los sistemas BCI y en el marco de una famosa competencia en entrenamiento de máquina para los sistemas BCI (BCI Competition), el análisis de la señal por CSP y sus variantes han demostrado ser una herramienta robusta.

En contraste a esta técnica, la aplicación del Análisis de Componentes Principales (PCA por sus siglas en inglés) y el Análisis de Componentes Independientes (ICA por sus siglas en inglés) que han sido métodos de preprocesamiento exitosamente usados en otros campos; se han notado menos efectivas para mejorar el rendimiento de la clasificación en los sistemas BCI. El avance del análisis CSP comparado con el PCA y el ICA puede en gran parte ser explicado por las diferentes estrategias concernientes al uso de las etiquetas de clase. Mientras el análisis por CSP explota la información que contienen las etiquetas de una manera supervisada, ICA y PCA son métodos no supervisados (Revista Scientia Et Technica, 2008).

4.5 Análisis por CSP

Produce filtros espaciales que son óptimos en cuanto a que extraen las señales que son más discriminantes entre dos condiciones. La técnica de CSP permite la identificación de los filtros espaciales que maximizan la varianza de las señales de una condición y al mismo tiempo minimiza la varianza de la señal con la otra condición. Este método ayuda a distinguir entre dos estados basados en imaginación motora (por ejemplo mover la mano derecha vs. la izquierda; mover la mano derecha vs. ambos pies). En contraste con PCA, el cual maximiza la varianza del primer componente en el espacio transformado, CSP maximiza la relación entre las varianzas de las dos condiciones o clases. Esta propiedad hace que el análisis por CSP sea uno de los filtros espaciales más efectivos para el procesamiento de las señales de las BCI basadas en EEG ya que permite que las intenciones de los usuarios estén codificadas en la varianza o la potencia de la señal cerebral asociada; técnicamente el algoritmo de los CSP otorga unos filtros espaciales basados en un criterio discriminativo. El algoritmo CSP requiere no solo el entrenamiento de las muestras sino también la información de la clase a la que pertenecen las muestras para calcular la matriz de transformación lineal; en contraste con PCA e ICA que no requieren de este tipo de información.

4.6 Selector de atributos

El problema de la selección de características implica seleccionar un mínimo subconjunto, con M características del conjunto de características, de manera que el espacio de características sea óptimamente reducido y el desempeño de la clasificación sea mejorada o no se degrade significativamente.

En esta etapa, el subconjunto mínimo de características se selecciona con bases y criterios de discriminación que permitan limpiar la señal captada de otras fuentes de onda que pueden o no haber sido registradas en el periodo de toma de muestra, usualmente por la activación muscular. En ese caso, señales con frecuencias mayores a 25Hz están más relacionadas a la actividad electromiográfica, por lo que es un criterio que nos permite seleccionar un subconjunto de características menor al número original sin empobrecer el desempeño de la clasificación.

4.7 Interface cerebro-computador (en su sigla en inglés BCI)

Una interfaz cerebro computador (BCI) es un sistema basado en adquisición de señales cerebrales mediante un ordenador, analizarlas y traducirlas en comandos que son retransmitidos a un dispositivo de salida para llevar a cabo una acción. En principio, cualquier tipo de señal cerebral puede ser usado para controlar un sistema BCI (Gabriel Ávila, 2016).

Un sistema BCI consta de 4 componentes secuenciales: (1) adquisición de la señal, (2) extracción de características, (3) interpretación de las características, (4) dispositivo de salida. Estos 4 componentes son controlados mediante un protocolo de operación que define el inicio y tiempo de operación, los detalles del procesamiento de la señal, la naturaleza de los comandos del dispositivo y la supervisión del rendimiento. Las interfaces cerebro computador eventualmente pueden utilizarse de forma rutinaria para reemplazar o restaurar la función útil de personas con discapacidades graves que se dan debido a trastornos neuromusculares. Una BCI también podría mejorar la rehabilitación de personas con ACV (Accidente Cerebro-Vascular), trauma craneal y otros trastornos (Jhon Muñoz, 2014).

El futuro de las BCIs depende a su vez del progreso de 3 áreas o aspectos críticos: desarrollo de hardware cómodo, conveniente y de adquisición de señal estable; la validación y difusión de las interfaces; y la puesta en prueba de la fiabilidad y la calidad de las BCI por parte de diferentes grupos de usuarios. La motivación prevalente de las BCIs ha sido prever tecnología de tipo asistida a personas con discapacidades físicas severas, como aquellas que producen parálisis completas e inhabilidades para hablar causadas por golpes o enfermedades crónicas. Por lo que suelen enfocar su aplicación final al manejo de máquinas como sistemas robóticos, prótesis, brazos electrónicos o cualquier otro tipo de máquina (Jhon Muñoz, 2014).

5. Metodología

5.1 Tipo de estudio

Estudio de modalidad descriptiva, observacional de corte transversal cuantitativo, con análisis de datos de manera descriptiva.

Este estudio no se considera experimental ya que sus variables no fueron modificadas, llevando los resultados solo a un contexto analítico y profundo para el avance del mismo. La dirección temporal de este estudio se considera transversal ya que las muestras realizadas y los datos obtenidos se realizaron en un solo momento determinado.

El enfoque del estudio es cuantitativo, ya que la obtención de datos, otorgados por la actividad eléctrica cerebral, traducida en datos numéricos, nos acerca a generar las respuestas suficientes de nuestra hipótesis de investigación.

5.2 Cálculo de tamaño muestral

Para el cálculo de tamaño muestral, se utilizó el cálculo a través de comparar múltiples promedios, los factores utilizados corresponden al modelo metodológico que aparece en este documento, que define como un diseño de estudio observacional, analítico comparativo, de corte transversal. Inicialmente se realiza un piloto con 4 sujetos de la población objetivo, tomando la media de la mejor variable y su desviación estándar.

La fórmula:

$$n \geq (1 + \sqrt{g-1}) \frac{(Z_{1-\alpha/2} + Z_{1-\beta})^2}{d^2} + \frac{Z_{1-\alpha/2}^2 \sqrt{g-1}}{2(1 + \sqrt{g-1})}$$

En donde, N= tamaño de la población, Z= nivel de confianza, α = valor 0,05, β = valor 0,2, d= efecto de tamaño (0,9999), g= número de grupo (3).

Para los propósitos de este estudio, el mínimo tamaño muestral requerido es de 21 sujetos.

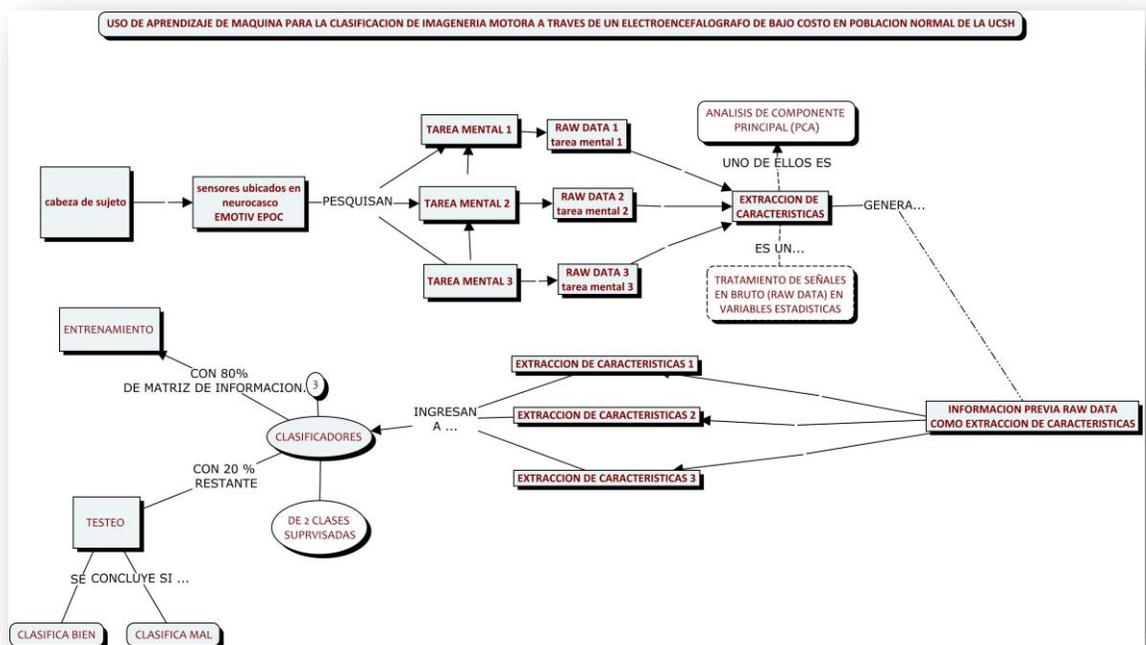
5.3 Participantes y criterios de exclusión

Estudiantes sanos de la comunidad formada en la UCSH son los sujetos propuestos para esta investigación por el fácil acceso para reclutar participantes en este grupo. Con el fin de generar resultados fiables y material de discusión al final del proyecto, los sujetos deberán tener una edad que comprenda entre los 18 y 24 años de edad, sin cabello crespo frondoso que dificulte la toma de muestra, ni una cantidad de tejido adiposo importante que pueda generar impedancia en los electrodos. Además, ninguno debe tener diagnosticada una patología neurológica ni mostrarse agotado tanto física como mentalmente para asegurar una señal limpia y estereotipada en los participantes.

5.4 Protocolo de toma de muestras

El protocolo descrito tiene como objetivo rescatar señales neuronales lo más fidedignas posibles dentro de nuestra limitante base (baja gamma del equipo) por lo que antes de comenzar la lectura se propicia un ambiente tranquilo, sin elementos externos que influyan en la atención del sujeto y con equipos que puedan causar interferencia electromagnética apagados, como celulares o radios. Una vez propiciado el ambiente, se entrena al usuario sobre la acción a imaginar, con el fin de invocar una actividad neuronal clara el operador le muestra de qué forma realizará la acción (puesto que diferentes sujetos pueden realizar una misma actividad de diferente forma) y se le pide que la realice

durante 20 segundos, luego, se le pide que imagine dicha acción con los ojos abiertos durante 20 segundos, y finalmente, debe imaginarla durante 20 segundos más con los ojos cerrados. Posterior al entrenamiento, se somete a la lectura de señales con el neurocasco durante 10 segundos imaginando la acción motora o cognitiva con los ojos cerrados. Es importante que la duración total de la toma de muestras no supere los 15 minutos para no generar un decaimiento en el nivel de concentración e influya en la intensidad o tipo de señal que se capte.



Mapa conceptual nos muestra flujo de los datos procesados del EEG.

5.5 Descripción de variables

5.5.1 Variables independientes (Clasificadores)

Se utilizarán tres métodos de entrenamiento para la clasificación de las señales recogidas cuya posterior comparación determinará cual es más confiable, siendo estos:

a) Adaboost: Es un algoritmo para el aprendizaje automático de máquinas clasificadoras capaz de adecuarse a otras fórmulas de aprendizaje y potenciar el resultado final que es la capacidad de clasificar correctamente. Tiene la particularidad de ajustar sus clasificaciones en función de acciones mal clasificadas anteriormente, generando que su rendimiento sea ligeramente mejor al anterior (Vanessa Gómez et al, 2006).

b) MLP (Perceptrón multicapa): Utilizando un algoritmo modificado del método perceptrón lineal, MLP funciona como una red neuronal artificial para clasificar datos que consiste en múltiples capas de nodos en un gráfico en donde cada capa está conectada a la siguiente. A diferencia de su predecesor, MLP utiliza una técnica de aprendizaje supervisado llamada *back propagation for training the network*, pudiendo distinguir datos que no son linealmente separables. Excepto para los nodos de entrada, cada nodo es una neurona con una función de activación no lineal (Wenjia Ouyang, 2013).

c) Tree J48: Es un algoritmo utilizado para generar un abanico de decisiones desarrollado por Ross Quinlan, siendo este una modificación de un sistema anterior (ID3) de Quinlan, pudiendo utilizarse incluso como un clasificador estadístico y cumpliendo para los propósitos de esta investigación.

5.5.2 Co Variable:

Clasificaciones realizadas con selector y sin selector de atributos. En este estudio fue utilizado el selector PCA (*Principal Component Analysis*), con la finalidad de que al realizar la extracción de característica la dimensionalidad del conjunto de datos se vea disminuida.

5.5.3 Variables dependientes:

Para invocar una señal cortical que permita entrenar con los distintos métodos las máquinas clasificadoras, se utilizaron dos tareas motoras (lanzar patada y aplaudir) y además una cognitiva (contar) con el fin de evidenciar si existe alguna diferencia notable al comparar dos tareas motoras con una motora y una cognitiva, pudiendo generar información de utilidad en futuras investigaciones.

a) Contar: Se le pide al sujeto que cuente indefinidamente a partir del número uno a su propio ritmo, imaginando cada número sobre una pared blanca cuando este los vocaliza.

b) Lanzar patada: Mientras el sujeto se encuentra sentado en una posición cómoda, se le pide que realice una extensión de rodilla izquierda rápida, repitiendo el proceso a su ritmo, con el fin de generar una patada simple.

c) Aplaudir: Sentado en una posición cómoda, se le pide al sujeto que realice aplausos con las palmas a su propio ritmo juntando ambas manos frente a su línea media con los codos en semiflexión.

5.6 Recolección de datos

El electroencefalógrafo utilizado para la captación de la imagen motora es el neurocasco Emotiv EPOC por ser más accesible a la clínica, convirtiéndolo en un candidato prometedor para llevar los beneficios de la imaginería motora a la comunidad en caso de lograr una mayor definición en las señales captadas. Los sujetos serán estudiantes seleccionados en el recinto de la Universidad Católica Silva Henríquez en la medida que cumplan una serie de requisitos orientados a minimizar los factores que entorpezcan la captación de las señales y firmen un consentimiento informado tras ser informados sobre los detalles del protocolo de muestreo. Como software para la interpretación de estas señales se escogió MATLAB por ser compatible con un tercer programa que permite la lectura de la información de EMOTIV por un bajo costo de inversión, finalmente, para la comparación de los resultados tras entrenar los clasificadores, se utiliza el software WEKA, este último por ser de carácter gratuito y capaz de comparar diferentes clasificadores dada su capacidad para emular cada uno.

5.7 Procesamiento de datos

Para el procesamiento de los datos se utilizaron las señales eléctricas dadas por el electroencefalógrafo Emotiv EPOC las cuales se pesquisaron durante la realización de las tareas mentales propuestas por los investigadores. Una vez tomados los datos estos llegan al ordenador desde el dispositivo mediante señales de bluetooth y wi-fi, filtradas análogamente de señales externas que puedan entorpecer la matriz, para luego ser sometidas a un proceso de filtrado más riguroso mediante el software MATLAB en el ordenador. Desde la mejora de señales y la eliminación de información aberrante hasta darle más énfasis a un canal sobre otro, se puede realizar en este proceso, todo para la recolección de datos más certera posible. Una vez filtradas y mejoradas estas señales a través del software MATLAB, llegan a un tercer destino, software WEKA 3.8, el cual nos permitirá llegar a la clasificación de las señales, y esclarecer las posibles diferencias de precisión que pueda haber entre unas y otras.

5.8 Análisis estadístico

Se realizó una prueba de normalidad de la distribución de los datos obtenidos a través de la prueba de normalidad, *D'Agostino&Pearson omnibus normality test*, demostrando que hay una normalidad estadística en el estudio. Luego, se realizará análisis de multivariadas (ANOVA de 3X2 y 3X3), de acuerdo a las vías propuestas por las tareas mentales a estudiar, siendo estas: Clasificadores MLP, Adaboost y TreeJ48 como variables independientes, y tres tareas mentales expuestas como variables dependientes, utilizando como co-variable un selector de atributos (PCA) al momento de realizarse la extracción de característica de cada señal eléctrica, con el fin de evidenciar si mejora su precisión con esta herramienta.

Estos métodos se detallarán a través de tablas con conjuntos numéricos, las cuales arrojarán promedios funcionales, que se estipularán como una herramienta más de estadística descriptiva.

6. Resultados

Los resultados procesados en datos numéricos, entregados por la plataforma de análisis de datos, arrojan determinadas características, las cuales serán resumidas en diferentes tablas, que grosso modo demostraran un análisis de los datos entregados, en primera instancia sin seleccionar un selector de atributos, y en segunda instancia con el selector de atributos, las que se analizaran posteriores a estas.

Precisión de la clasificación de la tarea mentales sin selector de atributo PCA (Análisis de los componentes principales).

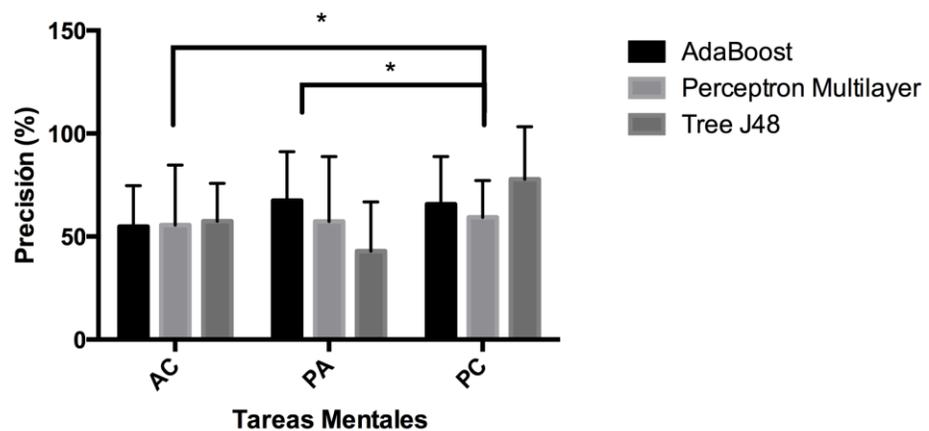


Grafico 6.1 muestra la precisión general en porcentaje de las tareas mentales agrupadas en dos clases, de acuerdo a los tres clasificadores aplicados, sin realizar un selector de atributos como arreglo estadístico.

Grafico 6.1.1	Clasificadores		
	Adaboost	Perceptron Multilayer	Tree J48
AC	55	56	57
PA	68	57	43
PC	66	59	78

Tabla 6.1.1 demuestra datos en detalle de grafico 6.1 que muestra resultados generales de la precisión general de las tareas mentales agrupadas en dos clases sin selector de atributos

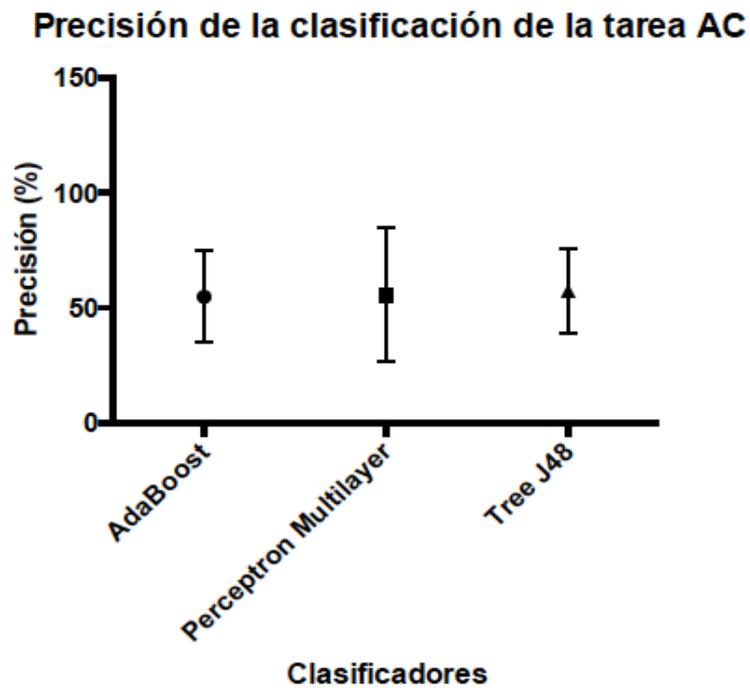


Grafico 6.1.2 muestra la precisión de los clasificadores ante la tarea AC (Aplaudir-Contar), dando como resultado estadístico, la no diferencia significativa entre variables. Los tres clasificadores se comportan de manera parecida frente a la misma tarea mental.

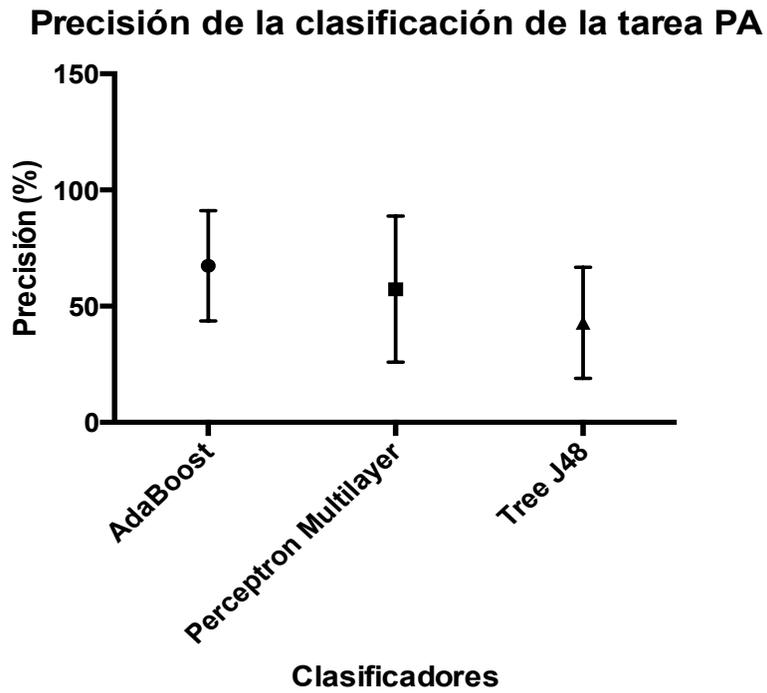


Grafico 6.1.3 revela precisión de los clasificadores frente a la tarea PA (Patada-Aplaudir), arrojando positivamente una diferencia significativa, entre el grupo de los clasificadores *ADABOOST* y *PERCEPTRON MULTIPLAYER*, en relación al clasificador *TREE J48*, determinando que el grupo de ambos clasificadores, realiza su tarea con mayor precisión frente al clasificador restante. Para este arreglo estadístico se utilizó un ANOVA de una vía, y arrojó un valor $P < 0,027$.

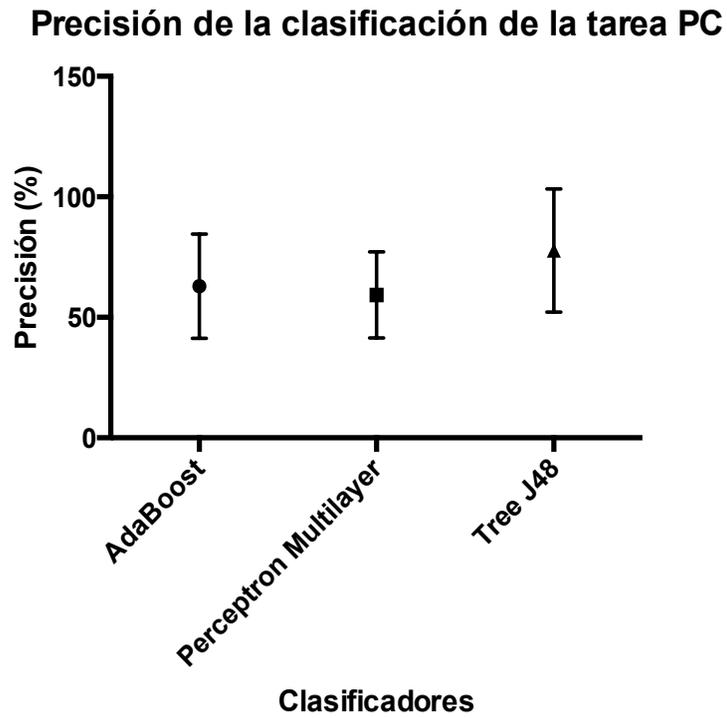


Grafico 6.1.4 evidencia la precisión de de los tres clasificadores frente a la tarea PC (Patada-Contar) siendo relevante el resultado del clasificador *TREE J48* dando como precisión un 78% en desmedro de los clasificadores *ADABOOST* y *PERCEPTRON MULTIPLAYER*, se encuentra además una diferencia significativa, dando un valor $P < 0,045$

De acuerdo a los resultados mostrados en los gráficos anteriores se establece que el clasificador de dos clases supervisado con mejor rendimiento es el *TREE J48* en la tarea mental PC (Patada-Contar), con lo cual vamos a ver en un siguiente grafico las tareas mentales restantes en el mismo clasificador y si hay diferencias entre ellas:

Comparación entre tareas en según el clasificador TreeJ48

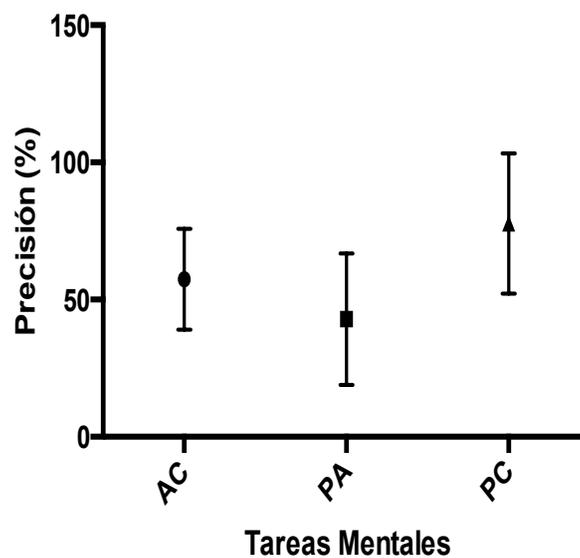


Grafico 6.1.5 establece la tarea PC (Patada-Contar) sigue siendo de mejor rendimiento frente a las otras tareas, bajo la precisión del mismo clasificador, además existe una diferencia significativa de las tareas AC (Aplaudir-Contar) y PA (Patada-Aplaudir) en relación a PC, de un valor $P < 0,0001$, validando el carácter de mejor clasificada de PC.

Precisión de la clasificación de la tarea mentales con selector de atributo PCA (Análisis de los componentes principales).

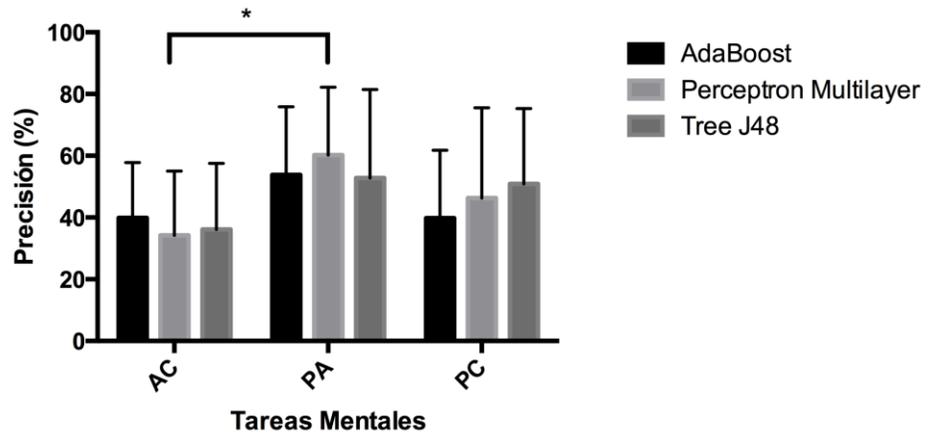


Grafico 6.2 muestra la precisión general en porcentaje de las tareas mentales agrupadas en dos clases, de acuerdo a los tres clasificadores aplicados, posteriores a realizar un selector de atributos como arreglo estadístico.

Tareas	Clasificadores		
	Adaboost	Perceptron Multiplayer	Tree J48
AC	40	34	36
PA	54	60	53
PC	40	46	51

Tabla 6.2.1 demuestra datos en detalle de grafico 6.2 que muestra resultados generales de la precisión general de las tareas mentales agrupadas en dos clases con selector de atributos PCA (análisis de componentes principales).

Precisión de la clasificación de la tarea AC en clasificadores con selector de atributo PCA (Análisis de los componentes principales).

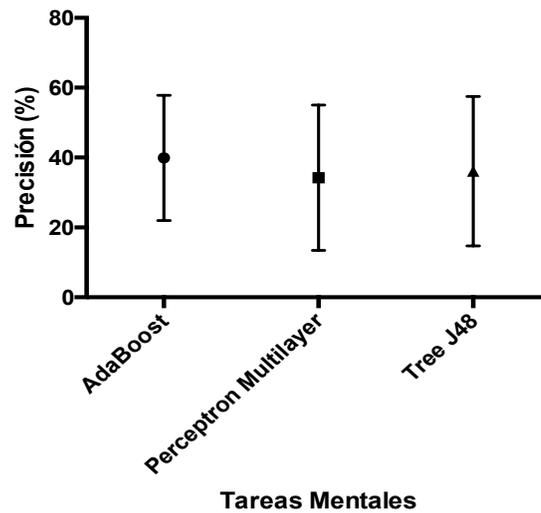


Grafico 6.2.2 muestra la precisión de los clasificadores ante la tarea AC (Aplaudir-Contar) con un selector de atributos (PCA), estableciendo que no existe diferencia significativa de acuerdo a variables estadísticas. Los tres clasificadores se comportan de manera parecida frente a la misma tarea mental y tienen una baja en su rendimiento en relación a los resultados, sin selector de atributos.

Precisión de la clasificación de la tarea PA en clasificadores con selector de atributo PCA (Análisis de los componentes principales).

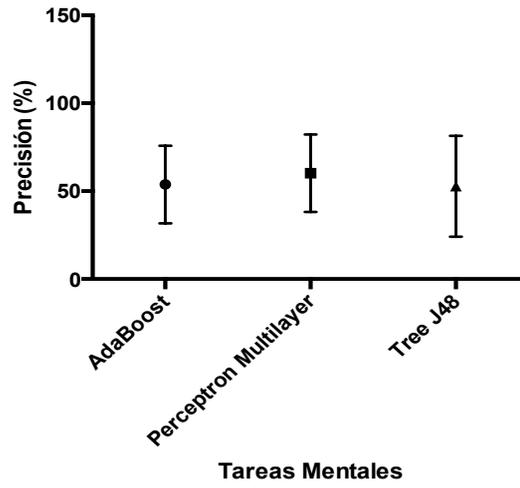


Gráfico 6.2.3 revela la precisión de los clasificadores ante la tarea PA (Patada-Aplaudir) con selector de atributos (PCA), dando como resultado estadístico, la no diferencia significativa entre variables. El rendimiento de los tres clasificadores se comporta de manera parecida frente a la misma tarea mental.

Precisión de la clasificación de la tarea PC en clasificadores con selector de atributo PCA (Análisis de los componentes principales).

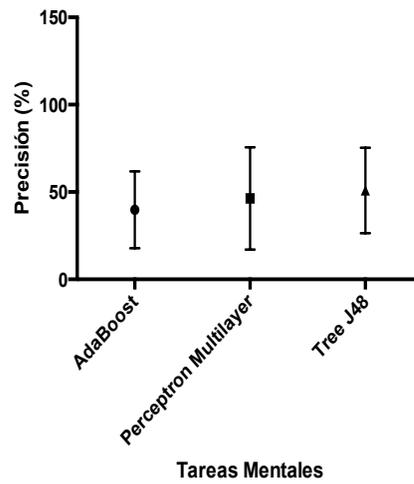


Gráfico 6.2.4 muestra la precisión de los clasificadores frente a la tarea PC (Patada-Contar) con selector de atributos (PCA), arrojando un resultado menor de precisión de los dos primeros clasificadores, *ADABOOST* y *PERCEPTRON MULTIPLAYER*, y manteniendo al *TREE J48*, como el mejor clasificador frente a esta tarea mental, sin embargo hubo una considerable baja porcentual en su rendimiento.

Para los siguientes gráficos comparativos se generó una matriz de datos, arrojando un ANOVA de dos vías, tomando tres variables (clasificadores), frente a dos factores, tarea mental AC (Aplaudir-Contar) y PC (Patada-Contar), sin selector de atributos y con selector de atributos.

Precisión de los clasificadores con y sin selector de atributo para la tarea mental AC

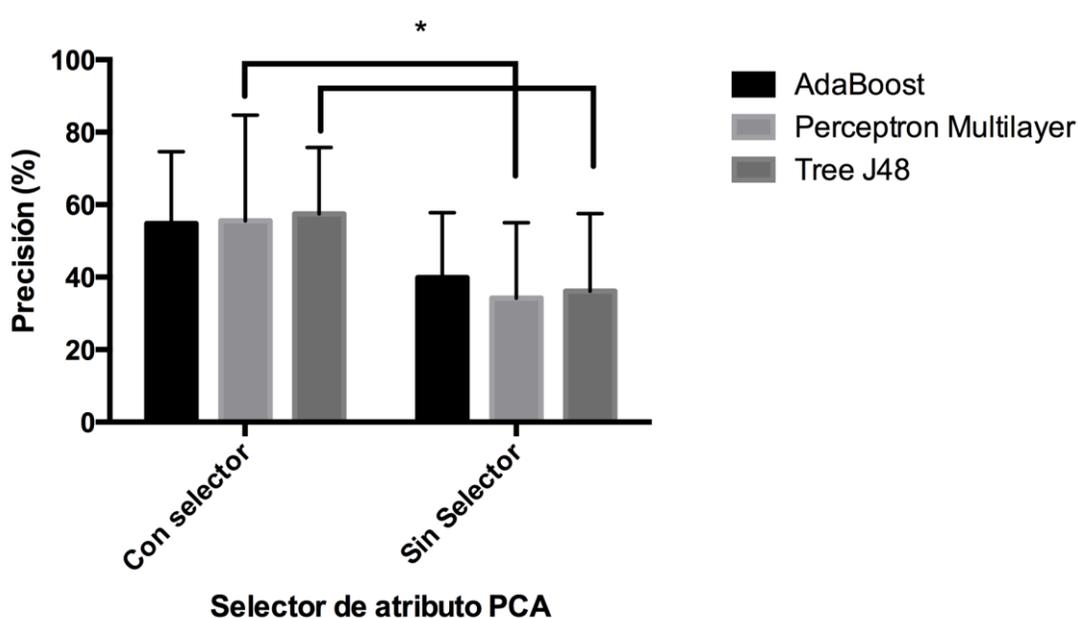


Grafico 6.3 establece la precisión de los clasificadores frente a los dos factores a analizar, estableciendo que la opción de no utilizar un PCA (análisis de los componentes principales) como un selector de atributos, es mejor para la correcta clasificación de tareas mentales en estos tres clasificadores.

Precisión de los clasificadores con y sin selector de atributo para la tarea mental PC

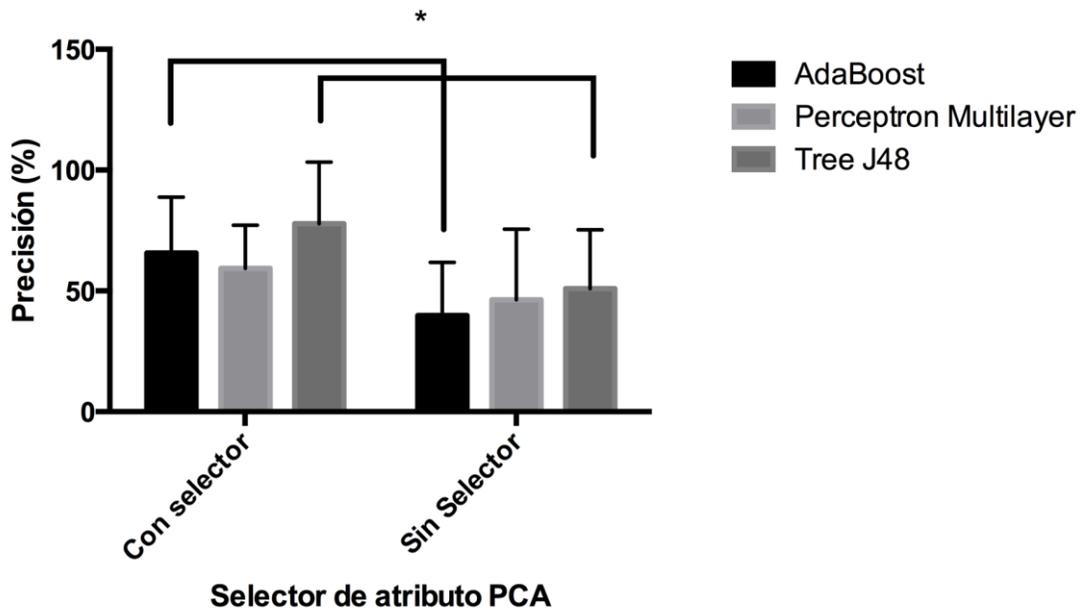


Grafico 6.3.1 muestra la precisión de los clasificadores frente a los dos factores a analizar, en este caso la tarea PC (Patada-Contar) mostrando la disminución de la precisión de los datos en la utilización del selector de atributos, sin embargo, el clasificador *TREE J48* sigue sobresaliendo frente a los demás.

7. Discusión

El conjunto de tareas mejor clasificado fue el de patada/contar por el clasificador Tree J48, y una de las maneras que más puede ayudar a mejorar su precisión es entender porque fue mejor. El contar requiere un recurso no menor de varios elementos, por lo tanto la diferencia en el reclutamiento geográfico del cerebro entre esta tarea y pegar una simple patada es muy diferente, dicha patada fue diseñada para describirse osteokinemáticamente como una simple extensión de rodilla izquierda, por lo que la zona cerebral requerida (asociada al homúnculo cortical) es mucho más focalizada en contraste a la tarea de contar y aplaudir (esta última, pese a ser igualmente motora, fue confeccionada para ser una acción más compleja al requerir más intervención muscular). Tree J48 demuestra ser útil para una multitud de necesidades más como la detección del cáncer de mama con un acierto cercano al 99% (E. Venkatesan, 2015) y algo más familiar a esta investigación como lo es la clasificación de enfermedades neurológicas por EEG (utilizando Tree J48 a través de WEKA) logrando una sensibilidad del 70%-100% y especificidad del 94%-100% (Deepika Kundra, 2014), por lo que resulta menester ahondar en posteriores estudios los factores que amplifiquen la utilidad de una herramienta tan prometedora.

Además, los resultados demuestran que existe una diferencia significativa en la precisión ($p < 0,05$) tanto de las tareas Aplaudir/Contar como Patada/Contar cuando son clasificadas con selector de atributo y sin selector de atributo, y pese a que en las tareas Patada/Aplaudir el valor p es $> 0,05$, si existe una tendencia a la baja de la precisión cuando se utiliza esta herramienta. Por lo tanto, las 3 variables presentan como común denominador el aumento de probabilidad de error al introducirse el selector de atributo en la extracción de característica. Dicha adición parece ser dañina para el correcto reconocimiento de patrones similares, sin embargo, confirma su efectividad en otras materias de investigación como el reconocimiento facial (Kwang In Kim, 2002), por lo que su uso no sería perjudicial, sino exclusivo para otros campos de la ciencia. Futuros estudios podrían no descartar experimentar el selector de atributos como co-variable, sino utilizar uno diferente al expuesto en este estudio con el fin de buscar factores que intensifiquen la precisión del clasificador Tree J48 con las tareas Patada/Contar.

8. Conclusión

Para la precisión de la realización de las tareas patada/contar el Tree J48 es del 78% distando de los otros grupos, por lo tanto, implica ser un muy buen candidato para emplear estudios a futuro solo para estas tareas.

Además, es importante considerar que al aplicar el concepto de selector de atributo PCA para poder clasificar, el sistema empeora el rendimiento del clasificador para las tareas aplaudir/contar y patada/contar, y aunque para las tareas patada/aplaudir no hay diferencia significativa, su precisión dista mucho de la lograda por el conjunto patada/contar en el clasificador Tree J48, por lo que su interacción con el selector de atributo deja de ser un objeto de estudio importante.

Debido a esto, este estudio sugiere que en futuras investigaciones donde se busque crear un sistema BCI (por ejemplo, un medio de comunicación para un paciente con síndrome de enclaustramiento) los pacientes sean entrenados con una tarea motora y una cognitiva con el fin de aumentar el margen de aciertos del clasificador, llegando hasta 7,8 de 10 aciertos si dichas tareas son lanzar una patada y contar clasificados por Tree J48, asumiendo un error asociado aproximadamente solo a un 22%.

9. REFERENCIAS

- Angélica Reyes Rueda (2013). Interfaz cerebro computador mediante la clasificación de señales electroencefalográficas.
- Alberto Morales Sánchez. Uso de características no lineales para identificar llantos de recién nacidos con un conjunto clasificador, 2015.
- Carlos Cupouy, Aplicación de árboles de decisión para la estimación del escenario económico y la estimación de movimiento la tasa de interés en Chile. 2014.
- Deepika Kundra et al. Classification of EEG based Diseases using Data Mining, 2014
- E. Venkatesan et al. Performance Analysis of Decision Tree Algorithms for Breast Cancer Classification, 2015
- Gabriel Ávila. InteractBCI: Adaptación de Técnicas de Interacción de HCI enfocada a Interfaces Cerebro-Computador, 2016.
- Imaginería mental: neurofisiología e implicaciones en psiquiatría
- Jafri Malin Abullah , Zamzuri Idris , Nor Safira Elaina Mohd Noor , Tahamina Begum , Faruque Reza , and Wan Ilma Dewiputri (2014).Future Use of EEG, ERP, EEG/MEG, and EEG-fMRI in Treatment, Prognostication, and Rehabilitation of Medical and Surgical Neurological Ailments
- Jhon E. Muñoz Cardona (2014). Clasificación de patrones de imaginación motora en una interfaz cerebro-computador de bajo costo usando software.
- Juan Mejiaz. Sistema de detección de intrusos en redes de comunicaciones utilizando redes neuronales, 2004
- Kamel Nidal, Aamir Saeed Malik. (2014). EEG/ERP Analysis: Methods and Applications
- Kwang In Kim et al. Face Recognition Using Kernel Principal Component Analysis, 2002
- McFarland, D. J., & Wolpaw, J. R. (2011). Brain-Computer Interfaces for Communication and Control. Communications of the ACM, 54(5), 60–66. <http://doi.org/10.1145/1941487.1941506>

Malouin F, Richards CL, Durand A. Slowing of motor imagery after a right hemispheric stroke. *Stroke Res Treat*. 2012.

- Pearson DG, Deeproose C, Wallace-Hadrill SM, Heyes SB, Holmes EA. Assessing mental imagery in clinical psychology: A review of imagery measures and a guiding framework. *Clin Psychol Rev*. 2012;33:1-23.

- Revista Scientia Et Technica. Técnicas de extracción de características en imágenes para el reconocimiento de expresiones faciales, 2008.

-Sarah N. Abdulkader, , Ayman Atia , Mostafa-Sami M. Mostafa. (2015). Brain computer interfacing: Applications and challenges . , de HCI-LAB, Department of Computer Science, Faculty of Computers and Information, Helwan University
Sitio web: <http://www.sciencedirect.com/science/article/pii/S1110866515000237>

- Shih, J. J., Krusienski, D. J., & Wolpaw, J. R. (2012). Brain-Computer Interfaces in Medicine. *Mayo Clinic Proceedings*, 87(3), 268–279. <http://doi.org/10.1016/j.mayocp.2011.12.008>

- Torres-García, A.A., Reyes-García, C.A., Villaseñor-Pineda, L., & Ramírez-Cortés, J.M.. (2013). Análisis de señales electroencefalográficas para la clasificación de habla imaginada. *Revista mexicana de ingeniería biomédica*, 34(1), 23-39. http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0188-95322013000100002&lng=es&tlng=es.

- Van der Meulen M, Allali G, Rieger SW, Assal F, Vuilleumier P. The influence of individual motor imagery ability on cerebral recruitment during gait imagery. *Hum Brain Mapp*. 2012.

10. ANEXOS:

10.1 Consentimiento informado para los sujetos en la toma de muestras:

Consentimiento informado para los Estudiantes de la Universidad Católica Silva Henríquez, que se les invita a participar en la investigación de “ENTRENAMIENTO DE MÁQUINAS CLASIFICADORAS PARA LA CORRECTA DIFERENCIACIÓN DE IMAGINERÍA MOTORA A TRAVÉS DE UN ELECTROENCEFALÓGRAFO DE BAJO COSTO EN POBLACIÓN NORMAL DE LA UCSH”.

Investigadores: Manuel Fernández- Cristián González

Pregunta de investigación: *¿existen diferencias entre los métodos de aprendizaje de máquinas para la correcta clasificación de imaginería motora, a través de un electroencefalógrafo de bajo costo en población normal de la ucsh?*

Hipótesis: Los estudiantes de la UCSH poseen aptitudes cognitivas válidas y pertinentes para la magnitud de la investigación.

Junto con el desarrollo de la humanidad, se han manifestado avances de toda índole en su población, la ciencia ha convertido a la salud en un nicho de investigación que abarca todos los aspectos necesarios para el mejoramiento diario de esta. De acuerdo a esta apreciación, se han mezclado áreas de la ciencia con tal de satisfacer las demandas necesarios para la solución de problemas, que no han podido tener solución, una de estas es la creación de imágenes abstractas, para la posibilidad de generar decisión sin emitir un gesto, una palabra, o una afirmación, es por esto que el proyecto que llevaremos a cabo se ha ahondado a tal punto de llegar a cualquier persona posible que requiera la asistencia permanente de otra, este proyecto busca a través de datos generar una matriz para futuras investigaciones en el área de la imaginería motora, y su futura asociación a una interface cerebro-máquina.

❖ TIPO DE INTERVENCION

Se le pedirá la realización e imaginación de tareas de índole motoras (ejecutar una acción) y de materia cognitiva (de imaginar una tarea), la cual se necesita la realización imaginada de estas, para censar su actividad cerebral a través del dispositivo evaluador

❖ SELECCIÓN DE PARTICIPANTES

Usted como estudiante activo de la UCSH, ha sido elegido para este estudio por el hecho de estar en una etapa decisiva en su formación de pregrado. Como estudiante, la complejidad de los contenidos de las actividades curriculares y el inicio de actividades académicas prácticas pueden llevar a un gran desarrollo de habilidades cognitivas, que permite que su actividad cerebral se mantenga dentro de los cánones que necesitamos para esta investigación.

❖ PARTICIPACION VOLUNTARIA

Su participación en esta investigación es totalmente voluntaria. Usted puede elegir participar o no hacerlo. Tanto sí elige o no participar, su decisión no tendrá ninguna consecuencia por parte de la universidad o del cuerpo docente de la escuela de Kinesiología. Usted puede cambiar de idea más tarde y dejar de participar aun cuando haya aceptado antes.

❖ PROCEDIMIENTOS Y PROTOCOLOS

El protocolo descrito tiene como objetivo rescatar señales neuronales lo más fidedignas posibles dentro de nuestra limitante base (baja gamma del equipo) por lo que antes de comenzar la lectura se propicia un ambiente tranquilo, sin elementos externos que influyan en la atención del sujeto y con equipos que puedan causar interferencia electromagnética apagados, como celulares o radios. Una vez propiciado el ambiente, se le entrena al usuario sobre la acción a imaginar, con el fin de invocar una actividad neuronal clara se le muestra de qué forma realizará la acción (puesto que diferentes

sujetos pueden realizar una misma actividad de diferente forma) y se le pide que la realice durante 20 segundos, luego, se le pide que imagine dicha acción con los ojos abiertos durante 20 segundos, y finalmente, debe imaginarla durante 20 segundos más con los ojos cerrados. Posterior al entrenamiento, se somete a la lectura de señales con el neurocasco durante 10 segundos imaginando la acción motora o cognitiva con los ojos cerrados. Es importante que la duración total de la toma de muestras no supere los 15 minutos para no generar un decaimiento en el nivel de concentración e influya en la intensidad o tipo de señal que se capte.

❖ DURACION DE LA INVESTIGACION

La toma de muestra no superara los 15 minutos de tiempo

❖ EFECTOS SECUNDARIOS

Esta investigación no conlleva ningún tipo de efecto secundario para usted.

❖ BENEFICIOS

No existe ningún tipo de beneficio para usted, aunque los resultados obtenidos por nuestra investigación ayudarán a aumentar la evidencia científica respecto a patologías asociadas a trastornos motrices, y datos relevantes útiles para futuras investigaciones del área de la ingeniería motora

❖ INCENTIVOS

No existen incentivos económicos ni de ninguna otra índole para usted por participar de esta investigación.

❖ CONFIDENCIALIDAD

Para resguardar su confidencialidad, los cuestionarios que usted responda serán solamente identificados con su Rut sin el número verificador, para evitar estigmatización de parte del entorno universitario respecto a las preguntas que pueda usted responder y los resultados serán de conocimiento solo del equipo investigativo.

Si tiene cualquier pregunta puede hacerlas ahora o más tarde, incluso después de haberse iniciado el estudio. Si desea hacer preguntas más tarde, puede contactar al investigador responsable:

- Manuel Fernández Sánchez /teléfono móvil : 94378172 /e-mail: manueluc.8@Gmail.com
- Cristián González Ibarra / teléfono móvil: 944419048 / e-mail: sibus@hotmail.cl

Acta de Consentimiento Informado

Acepto participar voluntariamente en la investigación “entrenamiento de máquinas clasificadoras para la correcta diferenciación de imaginería motora a través de un electroencefalógrafo de bajo costo en población normal de la ucsh”.

He sido informado(a) y he leído la información proporcionada. He tenido la oportunidad de preguntar sobre ella y se me ha contestado satisfactoriamente las preguntas que he realizado.

Consiento voluntariamente participar en esta investigación como participante y entiendo que tengo el derecho de retirarme de la investigación en cualquier momento sin que me afecte de ninguna manera.

Además, declaro saber que la información entregada será confidencial y solo será de conocimiento del grupo investigativo para el análisis.

NOMBRE COMPLETO DEL PARTICIPANTE Y RUT (Sin dígito verificador)

FIRMA DEL PARTICIPANTE

FECHA (DIA / MES / AÑO)

NOMBRE Y FIRMA DEL INVESTIGADOR RESPONSABLE