



**REGRESIÓN Y CARACTERIZACIÓN DE SEÑALES ELECTROENCEFALOGRÁFICAS  
EMPLEANDO TÉCNICAS DE INTELIGENCIA ARTIFICIAL**

**MARÍA ALEJANDRA BARAHONA GARCÍA  
LAURA VERONICA JARAMILLO MARÍN**

**UNIVERSIDAD ECCI  
FACULTAD DE INGENIERÍAS  
COORDINACIÓN DE INGENIERÍA BIOMÉDICA  
BOGOTÁ, D.C.**

**2022-2**



**REGRESION Y CARACTERIZACIÓN DE SEÑALES ELECTROENCEFALOGRÁFICAS  
EMPLEANDO TÉCNICAS DE INTELIGENCIA ARTIFICIAL**

**MARÍA ALEJANDRA BARAHONA GARCÍA  
LAURA VERONICA JARAMILLO MARÍN**

**Trabajo de investigación para optar al título de Ingeniero en Biomédica**

**RICARDO JARAMILLO DÍAZ**

**PROGRAMA INGENIERÍA BIOMÉDICA  
UNIVERSIDAD ECCI  
FACULTAD DE INGENIERÍAS  
COORDINACIÓN DE INGENIERIA BIOMÉDICA  
BOGOTÁ, D.C.**

**2022-2**

## Contenido

|  |    |
|--|----|
| <b>Título De La Investigación</b> .....                      | 11 |
| <b>1. Introducción</b> .....                                 | 11 |
| <b>2. Planteamiento Del Problema</b> .....                   | 15 |
| <b>3. Justificación</b> .....                                | 16 |
| <b>4. Hipótesis</b> .....                                    | 17 |
| <b>5. Objetivos</b> .....                                    | 18 |
| <b>5.1 Objetivo General</b> .....                            | 18 |
| <b>5.2 Objetivos Específicos</b> .....                       | 18 |
| <b>6. Estado Del Arte</b> .....                              | 19 |
| <b>7. Marco De Referencia</b> .....                          | 22 |
| <b>7.1 El Cerebro</b> .....                                  | 22 |
| <b>7.2 Plasticidad Cerebral</b> .....                        | 27 |
| <b>7.3 Accidente Cerebrovascular</b> .....                   | 27 |
| <b>7.4 Electroencefalografía, EEG</b> .....                  | 30 |
| <b>7.5 Inteligencia Artificial (IA)</b> .....                | 36 |
| <b>7.5.1 Concepto</b> .....                                  | 36 |
| <b>7.5.2 Tipos de Inteligencia Artificial</b> .....          | 37 |
| <b>7.5.3 Componentes</b> .....                               | 37 |
| <b>7.6 Interfaz Cerebro-Máquina</b> .....                    | 37 |
| <b>7.7 Aprendizaje Automático</b> .....                      | 38 |
| <b>7.7.1 Tipos De Aprendizaje</b> .....                      | 38 |
| <b>7.8 Algoritmos de regresión</b> .....                     | 39 |
| <b>7.8.1 Árboles de decisión</b> .....                       | 39 |
| <b>7.8.2 Bosques aleatorios</b> .....                        | 40 |
| <b>7.8.3 Máquinas de soporte vectorial</b> .....             | 40 |
| <b>7.8.4 Redes neuronales</b> .....                          | 40 |
| <b>7.9 Métricas de Evaluación</b> .....                      | 41 |
| <b>8. Metodología</b> .....                                  | 43 |
| <b>8.1 Origen de las señales de EEG procesada</b> .....      | 43 |
| <b>8.2 Delimitación de grupo de señales a utilizar</b> ..... | 44 |
| <b>8.3 Preprocesamiento</b> .....                            | 45 |
| <b>8.4 Entrenamiento de algoritmos</b> .....                 | 48 |
| <b>9. Resultados</b> .....                                   | 51 |

|       |   |    |
|-------|---|----|
| 9.1   | Preprocesamiento de los Datos.....                                      | 51 |
| 9.2   | Algoritmos de Regresión.....  | 53 |
| 9.2.1 | <i>Árboles de decisión</i> .....  | 53 |
| 9.2.2 | <i>Bosques Aleatorios</i> .....   | 55 |
| 9.2.3 | <i>Máquina de Soporte Vectorial</i> .....                               | 58 |
| 9.2.4 | <i>Red Neuronal</i> .....   | 59 |
| 9.2.5 | <i>Tiempo de ejecución de procesos en R</i> .....                       | 60 |
| 9.2.6 | <i>Comparación evaluación de métricas algoritmos de regresión</i> ..... | 61 |
| 10.   | Discusión.....  | 62 |
| 11.   | Conclusiones.....   | 64 |
| 11.   | Bibliografía.....   | 65 |

## Índice de Tablas y Figuras

|   |    |
|---|----|
| <b>Figura 1</b> Hemorragia Subaracnoidea .....  | 12 |
| <b>Figura 2</b> Vista Medial y lateral del Cerebro .....  | 23 |
| <b>Figura 3</b> Áreas de Brodmann .....   | 24 |
| <b>Figura 4</b> Homúnculo motor.....  | 25 |
| <b>Figura 5</b> Sistema internacional de disposición de electrodos 10-20.....                                 | 33 |
| <b>Figura 6</b> Patrón Alfa normal .....  | 34 |
| <b>Figura 7</b> Patrón Delta Lento.....   | 35 |
| <b>Figura 8</b> Potencial en espiga .....   | 35 |
| <b>Figura 9</b> Interfaz Cerebro-Máquina .....  | 38 |
| <b>Figura 10</b> Componentes de metodología .....   | 44 |
| <b>Figura 11</b> Relación entre sistema estandarizado de colocación de electrodos 10-20 y las funciones ..... | 45 |
| <b>Figura 12</b> Preprocesamiento de datos .....  | 46 |
| <b>Figura 13</b> Conversión de datos de EDF a CSV .....   | 47 |
| <b>Figura 14</b> Aprendizaje Supervisado por metodo de regresión.....   | 50 |
| <b>Figura 15</b> Comparación de señales F3 y F4 originales, para la predicción .....                          | 52 |
| <b>Figura 16</b> Árbol de decisión sin podar de 10 ramas .....  | 53 |
| Figura 17 Árbol podado de 5 ramas.....  | 54 |
| <b>Figura 18</b> Árbol de decisión sin poda .....   | 54 |
| <b>Figura 19</b> Árbol de decisión podado.....  | 55 |
| <b>Figura 20</b> Curva bosques aleatorios vs error .....  | 56 |
| <b>Figura 21</b> Señales Preponderantes .....   | 56 |
| <b>Figura 22</b> Señal comparativa .....  | 57 |
| <b>Figura 23</b> Comparativo de señal original vs predicción .....  | 57 |
| <b>Figura 24</b> Comparativo de puntos entre predicción y original .....                                      | 58 |
| <b>Figura 25</b> Real vs predicción .....   | 59 |
| <b>Figura 26</b> Red neuronal con 10 neuronas .....   | 59 |
| <b>Figura 27</b> Red neuronal con entradas de sensores hemisferio derecho .....                               | 60 |
| <br>  |    |
| <b>Tabla 1</b> Algunas de las principales conexiones anatómicas de la corteza cerebral .....                  | 26 |
| <b>Tabla 2</b> Factores de Riesgo .....   | 29 |
| <b>Tabla 3</b> Ondas Cerebrales .....   | 32 |
| <b>Tabla 4</b> Datos convertidos de EDF a CSV.....  | 51 |
| <b>Tabla 5</b> Tiempo de ejecución de modelos de regresión en R.....  | 60 |
| <b>Tabla 6</b> Métricas de Evaluación.....  | 61 |

Nota de aceptación:

---

---

---

---

---

---

---

---

Firma del presidente del jurado

---

Firma del jurado

---

Firma del jurado

Bogotá, 08 de agosto 2022



## **DEDICATORIA**

El presente trabajo de grado va dedicado a Dios, quien como guía estuvo presente en el caminar de mi vida, bendiciéndome y dándome fuerzas para continuar con mis metas trazadas sin desfallecer. Mi familia que, con su apoyo incondicional moral y económico, por su amor y confianza permitieron lograr un objetivo más en mi vida.

Alejandra Barahona García

A mi Amado Padre quien, con su responsabilidad, paciencia, transparencia en valores, tenacidad y amor al estudio, forjo en mi la persona que soy hoy, y al resto de mi familia por su apoyo incondicional y gran amor.

Verónica Jaramillo Marín

## AGRADECIMIENTOS

Agradezco a Dios, a mis padres y abuela por darme el apoyo necesario y la guía para llevar a cabo este proceso que ayuda al crecimiento personal y profesional.

Agradezco al Msc. Ricardo Jaramillo Díaz, quien, con sus conocimientos, su gran trayectoria, han permitido realizar este trabajo. Por su paciencia, tiempo, dedicación y brindarnos las guías necesarias.

Agradezco al Ingeniero Helberth Velásquez Ariza, por su tiempo, paciencia y dedicación en asesorar y apoyar también este trabajo de investigación.

A la Universidad ECCI y a todas las autoridades, por permitir concluir con una etapa de mi vida, gracias por la paciencia, orientación y guiarme en el desarrollo de esta investigación.

A mi compañera Verónica Jaramillo gracias por tu paciencia, y por compartir tus conocimientos en esta increíble aventura.

Fue una experiencia enriquecedora.

Alejandra Barahona García

A nuestro Estimado Profesor y guía Académico Ing, Ricardo Diaz quien mostró a lo largo del camino un apoyo y endereza incomparables, infinitas Gracias.

A mi compañera y Amiga Alejandra Barahona, gracias por tu paciencia, y por compartir tus conocimientos en esta increíble aventura.

Verónica Jaramillo Marín



## Resumen

El cerebro es un sistema de auto organización, las áreas internas del cerebro controlan el funcionamiento de los músculos; También controlan el habla, pensamiento, emociones, lectura, redacción y el aprendizaje. La reorganización de su estructura, función y conexiones se adaptan durante toda la vida esto se basa en la neuroplasticidad. La hipertensión arterial (HTA), el hábito de fumar, la diabetes mellitus, la fibrilación auricular y la dislipidemia y algunos hábitos modificables como el sedentarismo, la alimentación no saludable y el consumo desmedido de alcohol, tienen silenciosas, graves e irreversibles consecuencias como los accidentes cerebro vasculares (ACV), siendo la segunda causa de muerte en el mundo. Algunas de las técnicas de procesamiento de las señales cerebrales se basan en algoritmos de inteligencia artificial, para la extracción de características específicas, por medio de la señal de electroencefalografía (EEG). Los algoritmos de regresión forman parte de la estructura de la inteligencia artificial. La comparación y evaluación mediante las métricas estadísticas de la señal original y la señal predicha de EEG, determina la fiabilidad de los algoritmos de regresión empleados, árboles de decisión, bosques aleatorios, máquina de soporte vectorial y redes neuronales en procesos de predicción, servirá para posteriores procesos de rehabilitación. La predicción más cercana se evidencia por redes neuronales, presentan mayor gasto computacional, y requiere de un tiempo prolongado para evidenciar los resultados. Los árboles de decisión, bosques aleatorios y máquinas de soporte vectorial empleadas, generan resultados de predicción similar y requieren menor tiempo y gasto computacional.

**Palabras Clave:** Accidente Cerebrovascular, Neuroplasticidad, Inteligencia Artificial, Algoritmos de regresión.

## Abstract

The brain is a system of self-organization. The internal areas of the brain control the functioning of the muscles; They also control speech, thinking, emotions, reading, writing, and learning. The reorganization of its structure, function and connections are adapted throughout life this is based on neuroplasticity. High blood pressure (hypertension), smoking, diabetes mellitus, atrial fibrillation, and dyslipidemia. And modifiable habits such as sedentary lifestyle, unhealthy eating, and excessive alcohol consumption, have silent, serious, and irreversible consequences such as strokes, being the second leading cause of death in the world. The brain signal processing techniques are based on artificial intelligence algorithms, for the extraction of specific characteristics, by means of the electroencephalography (EEG) signal. Regression algorithms are part of the structure of artificial intelligence. Comparison and evaluation using statistical metrics of the original signal and the predicted EEG signal, determines the reliability of the regression algorithms used, decision trees, random forests, vector support machine and neural networks in prediction processes, it will serve for subsequent rehabilitation processes. The closest prediction is evidenced by neural networks, presents greater computational expenditure, and requires a long time to evidence the results. Decision trees, random forests, and vector support machines employed generate similar prediction results and require less computational time and expense.

**Keywords:** Stroke, Neuroplasticity, Artificial Intelligence, Regression Algorithms.

## Título De La Investigación

### **Regresión Y Caracterización De Señales Electroencefalográficas Empleando Técnicas De Inteligencia Artificial.**

#### **1. Introducción**

El cerebro, representa aproximadamente el 2 % del peso corporal, conteniendo miles de millones de neuronas y células gliales el termino neurona se refiere a la célula nerviosa unidad funcional y estructural, glial proviene del término griego pegante, mantiene el medio ambiente tisular para garantizar un adecuado funcionamiento neuronal (Osuna Suárez, Caro Henao, & Patiño Fernandez, 2016). La información se procesa en secuencia de pasos electrónico a gran velocidad en términos de milisegundos (ms). Protegido del ambiente externo por tres barreras: Cráneo, Meninges, Líquido cefalorraquídeo (Waxman, Stephen G, 2018).

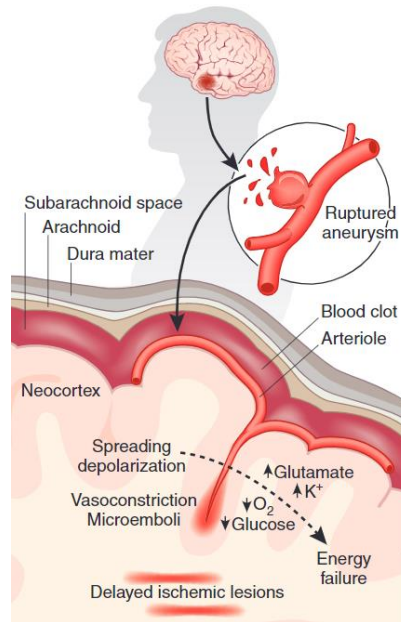
El cerebro actúa como centro de la actividad del sistema nervioso central (SNC), controlando funciones vitales como el ritmo cardíaco, digestión, respiración y presión arterial, algunas otras funciones relacionadas con las áreas motoras y cognitiva como dormir, caminar, hablar, pensar o procesar datos matemáticos (Snell, Richard S ; Sunyer, Claustre Pont;, 2014). Estando en constante adaptación. En él se producen impulsos eléctricos que viajan con información de una neurona a otra este proceso es conocido como sinapsis.

La plasticidad cerebral es la capacidad de alternación de las vías neuronales y la sinapsis del cerebro. La capacidad de ser modelado por experiencias, la capacidad de aprender y reorganizarse y recuperarse después de una lesión, que involucra la formación de nuevas vías neuronales y sinapsis ante los nuevos estímulos o modificación de estas (Pons, Raya, & González, 2016).

Cuando ocurre un aumento desmedido en la presión cerebro vascular conduce a la ruptura de los vasos sanguíneos subaracnoideos y consecuentemente a infartos cerebrales, generando la

desconexión de redes neuronales y bloqueando la función del área no irrigada, la ruptura de vasos en el área subaracnoidea se ilustra en la figura 1. Esto provoca muchas veces que el área del cerebro donde ocurre la lesión cerebral desarrolle una desconexión del área relacionada con la sinapsis de las neuronas, estos eventos suelen ser accidentes cerebro vasculares (ACV).

**Figura 1 Hemorragia Subaracnoidea**



*Nota. La hemorragia subaracnoidea, es generada por la ruptura de un aneurisma, presentando la bifurcación del flujo sanguíneo por el aumento de la presión, pasa de la base del cerebro hacia el espacio subaracnoideo y en la superficie del cerebro se presenta coagulación (Constantino, 2009).*

Los accidentes cerebrovasculares ACV son una de las principales causas de muerte y uno de los principales orígenes de discapacidades a largo plazo. La prevalencia mundial de los ACV para el año 2019 fue de 101,5 millones de personas de las cuales 6,6 millones de personas fallecieron atribuidas al ACV (American Heart Association, 2021). Tienen un costo estimado de

\$34 .000 millones de dólares al año. En adultos una de cada veinte muerte se debe a un accidente cerebrovascular. Muchas de estas muertes son prevenibles (CDC, 2017).

Al estar catalogado como una de las mayores causas de discapacidad, se orienta esta investigación en el estudio, regresión y caracterización de señales cerebrales en la predicción del registro de electroencefalografía (EEG) referente en condiciones patológicas. Empleando algoritmos de inteligencia artificial, en trabajos posteriores se podría realizar procesos de incorporación de señales estableciendo plasticidad neuronal artificial lo que representa un avance para los pacientes con discapacidad como consecuencia de ACV, disminuyendo costos relacionados con la rehabilitación y mejorando la calidad de vida del grupo objetivo.

La problemática actual de patologías no infecciosas de alto porcentaje de mortalidad y la prevalencia de discapacidad, según la organización mundial de la salud revela las principales causas de muerte y discapacidad en el periodo de los años 2000 a 2019, las cardiopatías , accidentes cerebrovasculares, diabetes, cáncer de pulmón y neumopatía obstructiva han generado la disminución de años de vida saludable *“La OMS revela las principales causas de muerte y discapacidad en el mundo: 200-2019”* (OMS, 2020) ,en la condición de vida de la persona que padece este tipo de afección y efectos ambientales, sociales y económicos que pueden llevar a un aumento de los accidentes cerebro vascular.

La integración de técnicas de procesamiento de imágenes médicas o de señales fisiológicas, que permitan una evaluación más acertada de la condición real de un paciente, con una lesión cerebral, puede mejorar la calidad de vida de los individuos que presentan la patología, los diagnósticos precisos y oportunos, permiten efectuar tratamientos apropiados para el paciente, para la recuperación o mayor autonomía del individuo.

El aprendizaje maquina se ha empleado para la clasificación de diferentes datos o características, en el análisis de la señal de EEG para la detección y diagnóstico de convulsiones automáticamente (WEN & ZHANG, 2018).

Se han generado estudios referentes al aprendizaje profundo para el desarrollo nuevos puentes o vías de reconexión neuronal, por medio de un proceso denominado aferentización que permite la regeneración neuronal (Sasmita, Andrew Octavian; Kuruvilla, Joshua ; Kiong Ling, Pick, 2018).

Anterior a este proceso se emplean algoritmos de regresión, es un método estadístico para modelar la relación entre una variable dependiente e independiente con una o más variables independientes. Comprende cómo cambia el valor de la variable dependiente correspondiente a una variable independiente cuando otras variables independientes se mantienen fijas. Predice valores continuos o reales (Jaiswal, Sonoo, 2021).

## 2. Planteamiento Del Problema

Según la organización mundial de la salud, el índice de supervivencia después de un accidente cerebro vascular es de 6 a 7 años, con aproximadamente el 85% de los pacientes que viven más allá del primer año del evento.

En la mayoría de los casos las personas que sobreviven a un accidente cerebro vascular realizan procesos de adaptación al entorno en que se encuentran; pero, no una rehabilitación para la lesión generada.

Las principales terapias se enfocan en adaptar al sujeto a las actividades cotidianas generando el aumento de la densidad de la materia gris y parte de la materia blanca en el cerebro (Cramer, Journal Of Stroke, 2018). La materia blanca está compuesta por axones mielinizados y la materia gris por pericariones y prolongaciones amielínicas. La materia blanca tiene la capacidad de transportar información neuronal mientras que la materia gris la procesa y almacena. Responsable de desarrollar respuestas apropiadas a diversos estímulos (Piquero, Iván, 2021).

Diferentes áreas del cerebro al trabajar en simultaneidad y con la información almacenada en sus núcleos para realizar algunas tareas conllevan a la posible recuperación a partir de unir las señales propiciando un proceso de regresión.

**¿Como generar un modelo de regresión de las señales de electroencefalografía para reconstruir una señal de un canal en específico?**

### 3. Justificación

El accidente cerebro vascular representa un riesgo elevado de muerte. Según la organización mundial de la salud, 15 millones de personas sufren un ACV en el mundo cada año, de estos, 5 millones mueren y el resto sobrevive con algún tipo de discapacidad, esto representa el 11,8% del total de muertes en el mundo (Benjamin EJ, y otros, 2017). La interrupción del flujo sanguíneo priva a las células nerviosas de los nutrientes necesarios para mantener las conexiones en las diferentes áreas del cerebro, lo que lleva a la necrosis y la pérdida de funciones, como la atención, hablar, leer, memoria a largo plazo, motricidad fina.

Los procedimientos orientados a tratar y restaurar regiones cerebrales afectadas por procesos isquémicos, para permitir la restauración de funciones, sino también para mejorar la calidad de vida de las personas que padecen este tipo de patología. Actualmente los estudios se enfocan en tratar los efectos colaterales generados por la isquemia cerebral retardada y la hemorragia subaracnoidea propiciando medios artificiales de comunicación. Por lo tanto, uno de los objetivos importantes del estudio es reconstruir la señal cerebral de un área específica empleando algoritmos de regresión.

La evaluación de los modelos aplicados permite determinar los algoritmos, que presentan un menor error, para la reconstrucción de la señal cerebral de un canal específico, analizando la confiabilidad de estos.

Por esta razón se propone el trabajo de regresión y caracterización de señales electroencefalográficas empleando técnicas de inteligencia artificial.



#### **4. Hipótesis**

La implementación de un algoritmo de inteligencia artificial permite usar la regresión y caracterización para reconstruir la señal cerebral, a partir de los registros cercanos al canal seleccionado, relacionadas con el área motora debido a que son áreas afectadas en un ACV.

## 5. Objetivos

### 5.1 Objetivo General

Predecir señales de electroencefalografía por medio de algoritmos de regresión con el fin de comprobar su confiabilidad para su posterior reconstrucción.

### 5.2 Objetivos Específicos

- Identificar el conjunto de señales cerebrales de electroencefalograma.
- Realizar preprocesamiento del registro de electroencefalograma.
- Implementar un algoritmo de aprendizaje maquina para la reconstrucción en la señal de EEG.
- Evaluar los algoritmos de regresión empleados.

## 6. Estado Del Arte

Según la organización panamericana de la salud la incidencia de defunciones por cardiopatía isquémica es de 73,6 muerte por 100.000 habitantes y por accidente cerebrovascular es de 32,3 muertes por 100.000 habitantes (OPS, 2021).

La principal causa de muerte en todo el mundo es la cardiopatía isquémica (una enfermedad causada por la aterosclerosis de las arterias coronarias, responsables del suministro de sangre al músculo cardíaco), que representa el 16% de todas las muertes en todo el mundo. Desde el año 2000, el mayor aumento de muertes se ha asociado con esta enfermedad, de más de 2 millones de muertes en 2000 a 8,9 millones en 2019. El accidente cerebrovascular y la enfermedad pulmonar obstructiva, es la segunda y tercera causa de muerte, respectivamente, y representa aproximadamente el 11 % y el 6 % de las todas las muertes. (Organización Mundial de la Salud, 2020)

Las técnicas empleadas en rehabilitación de áreas afectadas por un ACV se basan en terapias que direccionan o estimulan la neuroplasticidad, estas terapias están centradas en maximizar la función de áreas del cerebro no afectadas. (Cramer, y otros, 2017).

En procesos de rehabilitación de un ACV, exhibe un incremento de la conectividad, se presenta en dos tipos de redes de control cognitivo (redes fronto-parietal y cíngulo-opercular) este entrenamiento, promueve la generación de nuevas vías neuronales en la fase de recuperación de lesiones cerebrales traumáticas, evaluando la eficiencia de este tratamiento con biomarcadores (Han, Chapman, & Krawczyk, 2018). Este proceso se promueve mediante las actividades realizadas (Wenderoth, 2018), con ejercicios de movimiento, fuerza, respuesta sensorial, terapia de habla, se realizan repetitivamente para estimular la neuroplasticidad (Hoffman, 2019).

Después de una lesión cerebral, se da la activación de la génesis celular, y la reparación que es el cambio de las propiedades de vías neuronales existentes y nuevas conexiones neuronales, hay un proceso de reaprendizaje (Hermann & Chopp, 2014) (Sasmita, Andrew Octavian; Kuruvilla, Joshua ; Kiong Ling, Pick, 2018) (Zhang, Zhang, & Chopp, 2016).

El análisis del registro de EEG se realiza por el conjunto de los diferentes potenciales de grupos neuronales, abarcando áreas específicas del cerebro, con mayor precisión en áreas superficiales; En regiones con mayor profundidad el alcance del registro se ve limitado y los análisis generados presentan algunos déficits, donde los ritmos cerebrales se observan con menor resolución (Adhikaria, Epstein, & Dhamala, 2017).

Estudios referentes al aprendizaje automático para el desarrollo nuevos puentes o vías de reconexión neuronal por medio de un proceso denominado aferentización, que permite la regeneración neuronal (Sasmita, Andrew Octavian; Kuruvilla, Joshua ; Kiong Ling, Pick, 2018). El aprendizaje profundo se ha empleado para la clasificación de diferentes datos o características, en el análisis de la señal de EEG para la detección y diagnóstico de convulsiones de carácter automático (WEN & ZHANG, 2018).

Una representación en aprendizaje profundo para las características y funciones principales extraídas de una señal se realiza mediante una red neuronal. La clasificación de la inteligencia artificial aplicada mediante algoritmos para clasificación de imágenes o diseños de redes neuronales (Faust, Hagiwara, Hong, Lih, & Acharya, 2018).

Las técnicas de procesamiento de las señales cerebrales se basan en algoritmos, para la extracción de características específicas, para reducir el ruido que contamina la señal. Entre las técnicas de procesamiento se encuentran la regresión lineal, con base en coeficientes calculados, el patrón especial común, el análisis discriminante lineal, la validación cruzada y la geometría de

Riemann, que buscan técnicas modernas de procesamiento como el aprendizaje automático, un modelo a seguir es la clasificación del estado emocional por medio de la señal de EEG, como lo evidencia en el estudio realizado por **Xia-wei Wang, Dan Nie y Bao-Liang Lu** de “Emotional state classification from EEG data using machine learning approach” donde analizan la tendencia de los cambios emocionales, empleando un método de suavizado de características y un enfoque para rastrear la trayectoria de los cambios emocionales.

Comparando tres tipos de características específicas de la emoción EEG, y evaluando el desempeño de la clasificación de dos estados emocionales a partir de datos EEG de seis sujetos. Sobre modelos emocionales, describiendo la extracción de características, suavizado de características, reducción de dimensionalidad de características, clasificación y trayectoria de los cambios emocionales (Dan & Bao, 2014).

## 7. Marco De Referencia

Con la finalidad de fundamentar la investigación y comprender sus principios, en esta sección, se describe de forma detallada cada uno de los elementos, conceptos de la teoría, que son directamente empleados en el desarrollo del proyecto. Se inicia con terminología relacionada a la fisiología y anatomía, adentrando en las estructuras principales del estudio. Posteriormente se describe la carga de la enfermedad de ACV en estadísticas mundiales y nacionales. Luego se definen los algoritmos de regresión empleados en el desarrollo y por consiguiente los parámetros de evaluación para los modelos de inteligencia artificial usados.

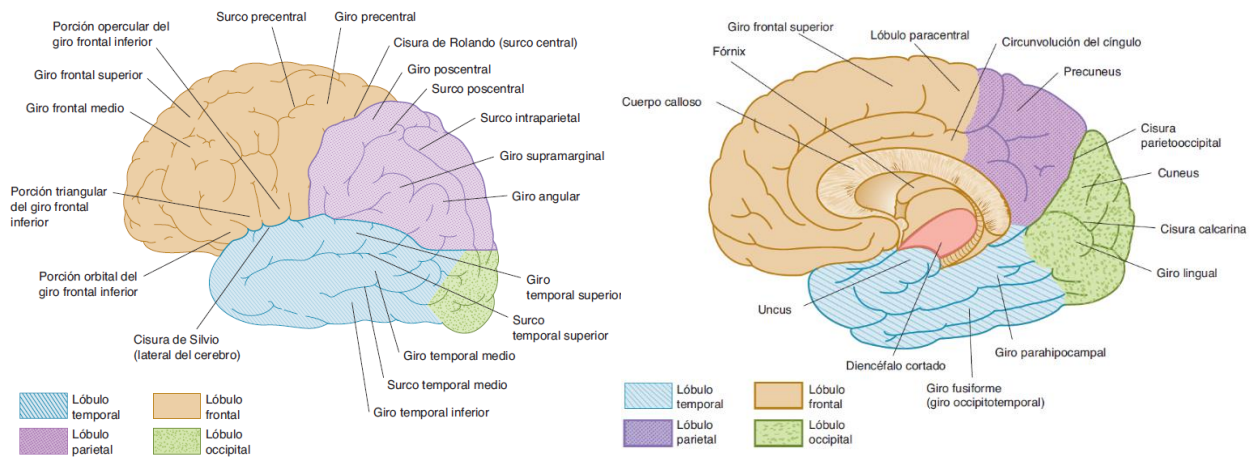
### 7.1 El Cerebro

El cerebro es considerado un sistema de auto organización, es decir la evolución de un sistema en forma organizada en ausencia de medios externos, adaptándose durante toda su vida, esto se basa en la neuroplasticidad, que es la capacidad del sistema nervioso para responder a estímulos intrínsecos o extrínsecos, mediante la reorganización de su estructura, función y conexiones (Khan, Amatya, Galea, Gonzenbach, & Kesselring, 2016).

Las diferentes regiones de la corteza cerebral pueden asociarse con funciones particulares, un concepto conocido como localización de funciones. La estructura y organización del cerebro se dividen dos hemisferios, que a su vez se subdividen en cuatro lóbulos. Los lóbulos se denominan según los huesos que los cubren: frontal, parietal, temporal y occipital se detallan los giros y cisuras principales de cada hemisferio en la figura 2 (Tortora & Derrickson).

El telencéfalo o cerebro terminal, da lugar a los hemisferios cerebrales izquierdo y derecho. Los hemisferios cerebrales incluyen la corteza cerebral, que está constituida por seis lóbulos: frontal, parietal, temporal, occipital, insular y límbico, la sustancia blanca cerebral y un complejo de masas profundas de sustancia y los ganglios basales.

**Figura 2** Vista Medial y lateral del Cerebro



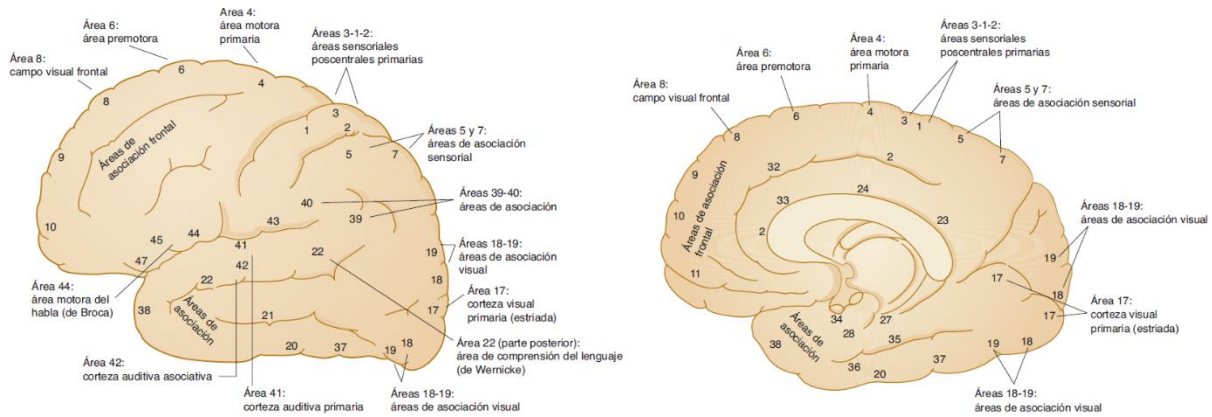
*Nota. Vista lateral del hemisferio cerebral izquierdo, donde se muestran los giros y cisuras principales. Vista medial del hemisferio cerebral derecho (Waxman, Stephen G, 2018)*

El lóbulo frontal se divide en dos secciones, lado izquierdo y derecho, esto se debe a la asimetría que presenta. Alrededor del 85% de las personas, la sección izquierda se encarga principalmente del lenguaje y la articulación de las palabras, el lado derecho está relacionado con movimientos no verbales, como la expresión facial. Las áreas de localización asociadas con las demás funciones realizadas en el lóbulo varían de persona a persona (NURORHB; Vinalopó, Vithas ;, 2017).

Lóbulo frontal que incluye no sólo la corteza motora, sino también, áreas frontales de asociación responsables de la iniciativa, el juicio, el razonamiento abstracto, la creatividad y la conducta socialmente apropiada se extiende desde el polo frontal, hasta la cisura de Rolando y la cisura de Silvio. La corteza prefrontal, que incluye la corteza asociativa de orden superior implicada en el juicio, razonamiento, iniciativa, conducta social de orden superior y funciones similares, se localiza con anterioridad a la corteza motora primaria dentro del giro precentral y la corteza premotora adyacente. El estudio de las áreas funcionales y de las regiones presentes en cito arquitectura del cerebro se realiza mediante el mapeo de las áreas de Brodmann, que permite

asociar las funciones con localización específica, la distribución de áreas se presenta en la figura 3.

**Figura 3** Áreas de Brodmann



*Nota. Aspecto lateral del cerebro. Se muestran las áreas corticales según Brodmann con localizaciones funcionales, Aspecto medial del cerebro. Se muestran las áreas corticales según Brodmann con localizaciones funcionales. (Waxman, Stephen G, 2018)*

Las áreas de Brodmann relacionadas con la corteza motora son: Área 4,6, comprenden las funciones de corteza motora primaria, premotora, motora suplementaria.

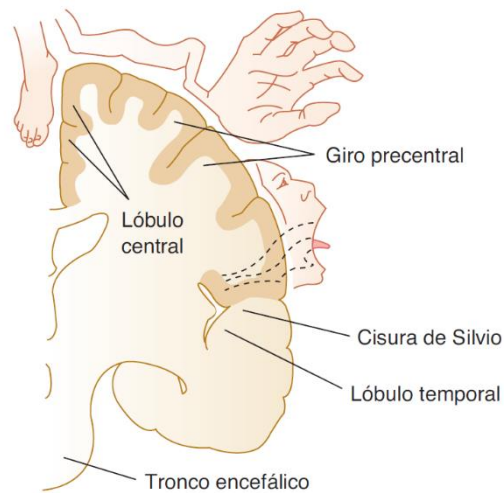
El área motora primaria en el giro prefrontal. Las neuronas piramidales de gran tamaño y neuronas más pequeñas dentro de esta área dan lugar a muchos de los axones que descienden como tracto corticoespinal.

La corteza motora está organizada en sentido somato tópico: los labios, lengua, rostro y manos se representan en orden dentro de un homúnculo tipo mapa en la parte inferior de la convexidad del hemisferio. Estas partes corporales tienen un tamaño magnificado en la forma en que se proyectan sobre la corteza, lo que refleja la gran cantidad de corteza dedicada al control fino y a los movimientos buco linguales. El brazo, tronco y cadera se representan en orden en la parte superior de la convexidad; y el pie, parte inferior de la pierna y los genitales se encuentran dispuestos dentro de la cisura interhemisférica.



El homúnculo es una representación anatómica de las cortezas cerebrales, descrito por el doctor Wilder Penfield, como un mapa sensorial del cuerpo humano. La figura 4 representa el homúnculo motor, encargado de controlar y regular los movimientos.

**Figura 4 Homúnculo motor**



*Nota. Homúnculo motor dibujado sobre un corte coronal a través del giro precentral.*

*Se muestra la localización del control cortical de diversas partes del cuerpo. (Waxman, Stephen G, 2018)*

La corteza prefrontal tiene extensas conexiones recíprocas con el tálamo anterior dorso medial - ventral y con el sistema límbico. Esta área de asociación recibe e integra la información de múltiples modalidades sensoriales.

La memoria del área motora es almacenada en el sistema nervioso central, estructurándose y modificando rápidamente, debido al entrenamiento referente a áreas motoras. Los medios celulares que permiten regular este nivel de neuroplasticidad son las sinapsis, que regulan la transferencia de información de una neurona a otra. La sinapsis tiene la capacidad de modificar la eficacia de transferencia de información entre células nerviosas denominado plasticidad sináptica.

La neuroplasticidad en un cerebro adulto se forma a partir de las actividades realizadas en relación actividades físicas, aprendizaje y sensoriales. (Wenderoth, 2018). Se evidencian las principales conexiones anatómicas de la corteza cerebral, se dividen en dos grupos principales que son sensitiva y motora clasificadas en las áreas de Brodmann estos se relacionan en la tabla 1.

**Tabla 1** Algunas de las principales conexiones anatómicas de la corteza cerebral

| <b>Función</b>            | <b>Origen</b>   | <b>Área cortical</b>  | <b>Destino</b>  |
|---------------------------|---|---|---|
| Somato sensitiva.         | Núcleos de tálamo ventral posterolateral y ventral posteromedial.                       | Área somestésica primaria (B3, B1 y B2), circunvolución posterior central | Área somestésica secundaria; área motora primaria.  |
| Visual.                   | Cuerpo geniculado lateral.  | Área visual primaria (B17).   | Área visual secundaria (B18 y B19).   |
| Auditiva.                 | Cuerpo geniculado medial.   | Área auditiva primaria (B41 y B42).                                       | Área auditiva secundaria (B22).   |
| Gustativa.                | Núcleo solitario.   | Circunvolución posterior central (B43).                                   |   |
| Olfativa.                 | Bulbo olfatorio.  | Área olfatoria primaria; áreas periamigdalina y prepiriforme.             | Área olfatoria secundaria.  |
| Motora Movimientos finos. | Tálamo desde el cerebelo, ganglios de la base; área sensitiva somática; área premotora. | Área motora primaria (B4).  | Núcleos motores del tallo cerebral y células de la asta anterior de la médula espinal; cuerpo estriado. |

*Nota. las principales conexiones anatómicas de la corteza cerebral se dividen en dos grupos principales que son sensitiva y motora, distribuidas en las áreas de Brodmann.*

(Wenderoth, 2018)

La clasificación de señales es de importancia en diferentes aspectos de los sistemas de interfaz cerebro-máquina, como para el diagnóstico lesiones o patologías cerebrales de esta manera el aprendizaje profundo se ha empleado para la clasificación de diferentes datos o características,

en el análisis de la señal de EEG para la detección y diagnóstico de convulsiones automáticamente, con redes neuronales aplicadas (WEN & ZHANG, 2018).

En la identificación por medio del registro del registro de EEG, en la mayoría de los casos se relaciona con la experticia del médico especialista, la resolución de la señal, presentando algún margen de error en la identificación de la patología y su afectación.

## **7.2 Plasticidad Cerebral**

Es la capacidad de alteración de las vías neuronales y la sinapsis del cerebro, la capacidad de ser modelado por experiencias, la capacidad de aprender y reorganizarse y recuperarse después de una lesión en el sistema nervioso, ante una lesión, que involucra la formación de nuevas vías neuronales y sinapsis ante los nuevos estímulos o modificación (Pons, Raya, & González, 2016). La neuroplasticidad es la base neurobiológica de la capacidad de adaptarse a mecanismos de aprendizaje. En concepto estructural, la plasticidad neuronal podría definirse en términos de: densidad de la espina, las ramificaciones, número y tamaño de sinapsis, densidad del receptor y en algunas regiones del cerebro y el número de neuronas relacionadas (Hermann & Chopp, 2014).

Después de una lesión cerebral se da la activación de la génesis celular de las áreas cerebrales afectadas y la reparación que es el cambio de las propiedades de vías neuronales existentes y nuevas conexiones neuronales, hay un proceso de reaprendizaje. (Hermann & Chopp, 2014) (Sasmita, Andrew Octavian; Kuruvilla, Joshua ; Kiong Ling, Pick, 2018) (Zhang, Zhang, & Chopp, 2016)

## **7.3 Accidente Cerebrovascular**

Es una lesión cerebral aguda, con consecuencias permanentes en la capacidad funcional (Chen, Shen, Chen, & Dai, 2017). Subdividido en, isquémicos (IS por sus siglas en inglés) la cual describe

la disminución del flujo sanguíneo, privando al tejido cerebral de los recursos necesarios, esto puede desencadenar un embolismo, trombosis o disminución de la perfusión sistémica.

El tipo hemorrágico (SAH por sus siglas en inglés) es la ruptura de conductos cerebrovascular, cuya hemorragia daña vías conectivas y las sustancias bioquímicas liberadas durante y después del evento tienen efectos adversos hasta la necrosis tisular de materia blanca o gris; catalogadas en hemorragias subaracnoideas, intracerebrales, subdural o epidural (Caplan, 2009).

El accidente cerebro vascular representa un riesgo elevado de muerte. Las personas que sobreviven pueden experimentar pérdida de visión, habla, confusión y alguna categoría de parálisis (World Health Organization, 2019).

Según la organización mundial de la salud, 15 millones de personas sufren un ACV en el mundo cada año, de estos, 5 millones mueren y el resto sobrevive con algún tipo de discapacidad, esto representa el 11,8% del total de muertes en el mundo (Benjamin EJ, y otros, 2017).

En la Unión Europea (UE) el ACV es la principal causa de muerte, es responsable de más de 1,1 millones de muertes cada año y representa el 35% de la totalidad de muertes, hay más de 100.000 ACV en el Reino Unido cada año; eso es alrededor de un ACV cada cinco minutos (Past & Future of Stroke Care in Europe, 2017). En Canadá representa el 7% de todas las muertes anualmente, es equivalente a 15.409 canadienses. En Estados Unidos cada año, aproximadamente 795,000 personas experimentan un accidente cerebrovascular nuevo o recurrente. Alrededor de 610,000 de estos son primeros ataques, y 185,000 son ataques recurrentes (Benjamin EJ, y otros, 2017).

En Colombia, los principales lugares con mayor número de casos de ACV son: Bogotá, Valle del Cauca, Antioquia y Santander. En el boletín de cardiología se evidencia durante el transcurso del año 2015 en Santander se presentaron 3500 casos de ACV isquémico y alrededor

de 400 casos de tipo hemorrágico (Sieger, 2016). Aproximadamente el 85% de los pacientes que sobreviven más allá del primer año del ACV, la mayoría de los pacientes que sobreviven sufren algún tipo de discapacidad permanente (Cramer, Journal Of Stroke, 2018).

Una de las principales causas es la intoxicación por monóxido de carbono puede causar secuelas neurológicas y cardíacas. Cuando es aguda por monóxido de carbono, puede provocar lesiones graves en cerebro, corazón y otros órganos; los daños más severos que podrían presentarse en el cerebro incluyen isquemia cerebral e hipoxia, edema, degeneración neuronal y necrosis de las células neurales (Kara, Bayir, Ak, & Degirmenci, 2015).

La clasificación de los factores de riesgos se da en modificables, no modificables y nuevos factores de riesgo relacionados en la Tabla 2.

**Tabla 2 Factores de Riesgo**

| No modificables | Modificables                 | Nuevos                              |
|-----------------|------------------------------|-------------------------------------|
| Edad.           | Hipertensión arterial.       | Ateromatosis arco aórtico.          |
| Sexo.           | Diabetes.                    | Aneurisma del septo interauricular. |
| Raza.           | Tabaquismo.                  | Foramen oval permeable.             |
| Herencia.       | Obesidad- Sobrepeso.         | Bandas auriculares.                 |
| ACV anterior.   | Colesterol alto.             | Flujo lento en cavidades cardíacas. |
|                 | Dislipidemia.                | Migraña.                            |
|                 | Síndrome metabólico.         |                                     |
|                 | Arritmias cardíacas.         |                                     |
|                 | Enfermedad coronaria.        |                                     |
|                 | Anticonceptivos orales.      |                                     |
|                 | Drogas psicoactivas.         |                                     |
|                 | Consumo excesivo de alcohol. |                                     |

*Nota. Los factores de riesgos predominantes en los accidentes cerebro vasculares están categorizados en tres grupos: No modificables, modificables y Nuevos (Pérez R, Germán Enrique, 2007)*

El examen más usado en diagnósticos es el EEG, permite traducir las señales físicas en señales análogas que son en factor de una frecuencia.

La electroencefalografía (EEG) permite observar el seguimiento de recuperación de un paciente con alguna anomalía en su lectura de ondas cerebrales. La electroencefalografía cuantitativa (QEEG) muestran la amplitud de las señales del tejido cerebral en áreas específicas de estudio, la simultaneidad de la señal requiere un proceso de transformación para obtener las características de frecuencias frente al espectro de potencia. La manifestación eléctrica de la polarización y despolarización celular del cerebro puede verse afectada cuando la perfusión cambia y el metabolismo celular es afectado por flujo sanguíneo incorrecto (Lazaridis & Smielewski, 2013) (Adhikaria, Epstein, & Dhamala, 2017).

#### **7.4 Electroencefalografía, EEG**

Se realiza por medio de los diferentes potenciales de grupos neuronales, abarcando áreas específicas del cerebro, con precisión en zonas superficiales, en regiones con profundidad el alcance del registro se ve limitado y los análisis generados presentan algunos déficits, donde los ritmos cerebrales se observan con menor resolución (Adhikaria, Epstein, & Dhamala, 2017). Las funciones cognitivas, como la transferencia de información, la percepción, el control motor y los diferentes tipos de memoria. Los potenciales que representa la actividad neuronal de interés relacionado con un estímulo específico (Nidal & Malik, 2015).

El examen de diagnóstico más común es el electroencefalograma reconocido por sus siglas EEG, permite observar la actividad electroquímica del cerebro, la sinapsis (es la comunicación entre neuronas que se convierten en impulsos eléctricos que pueden medirse con su frecuencia en Hz) la señal capturada se genera principalmente por las neuronas piramidales en las áreas corticales de la corteza cerebral. Esta comunicación efectiva entre neuronas también tiene presencia en ondas

que incluso está presente en la hora del sueño o vigilia. La actividad eléctrica generada por grupos de neuronas se puede caracterizar por la frecuencia, amplitud y fase de oscilaciones. (Nidal & Malik, 2015).

El registro de EEG, permite analizar la neuroplasticidad, mediante diversos estímulos. para personas que han sufrido afectación neurológica derivada de un ACV ya sea parcial o total, localizada (focal) o de naturaleza hemorrágica, su función es estimular el sistema nervioso para conformar nuevas vías de conexión, para definir nuevas tareas o las mismas que realizaba antes de una manera diferente (Cramer, y otros, 2017).

El registro del EEG es la suma de la actividad eléctrica de un grupo de neuronas, probablemente miles. La actividad generada por los grupos de neuronas se puede caracterizar por la frecuencia y amplitud. En el cerebro humano se presentan seis tipos de bandas cerebrales, clasificadas por sus rangos de frecuencia y amplitud. Estas se conocen como alfa ( $\alpha$ ), theta ( $\theta$ ), beta ( $\beta$ ), delta ( $\delta$ ), gamma ( $\gamma$ ) y mu ( $\mu$ ) (Cárdenas Gómez, 2021). En la tabla 3 se observan los diferentes tipos de ondas, con la frecuencia de banda, la amplitud y las características principales.

**Tabla 3 Ondas Cerebrales**

| <b>Tipo de Onda</b> | <b>Banda de Frecuencia</b> | <b>Voltaje</b>           | <b>Características</b>   |
|---------------------|----------------------------|--------------------------|--|
| Delta.              | 0.5Hz a 4Hz                | 20 $\mu$ V a 200 $\mu$ V | Son las ondas de mayor amplitud y menor frecuencia. Se generan ante un estado de sueño profundo. Estas ondas tienen mayor amplitud en comparación con los otros ritmos cerebrales, pero tienen la frecuencia más baja.   |
| Theta.              | 4Hz a 7.5Hz                | 20 $\mu$ V a 100 $\mu$ V | Se registran en las zonas parietal y temporal, están asociadas con inspiración creativa y profunda meditación. Son ondas de mayor amplitud y menor frecuencia.   |
| Alpha.              | 8Hz a 13Hz                 | 20 $\mu$ V a 60 $\mu$ V  | Están asociadas con la relajación, la desconcentración y la inactividad cerebral, estas ondas son de mayor amplitud que las ondas beta y son más lentas.   |
| Beta.               | 14Hz a 35Hz                | 2 $\mu$ V a 20 $\mu$ V   | Generadas cuando el cerebro está despierto e implica actividades mentales. Son ondas amplias y de mayor velocidad de transmisión. Denotan una actividad mental intensa.  |
| Gamma.              | 30Hz a 80Hz                | 5 $\mu$ V a 10 $\mu$ V   | Se presenta como respuesta a estímulos sensoriales o sonidos contundentes. Ocurren raramente en el cerebro, suelen presentarse en el procesamiento de las actividades sensorial intermodal, esto quiere decir en el proceso de combinar diferentes sentidos como la vista y el sonido. |
| Mu.                 | 8Hz a 13Hz                 | 20 $\mu$ V a 60 $\mu$ V  | las ondas mu están relacionadas con el rendimiento y el aprendizaje de las habilidades motoras. Relacionada con la actividad cerebral de múltiples tareas realizadas al mismo tiempo. Se observa el disparo sincrónico de las neuronas motoras sobre la corteza sensorial-motora.      |

*Nota. Los ritmos cerebrales se clasifican por su amplitud y frecuencia. (Cárdenas Gómez, 2021)*

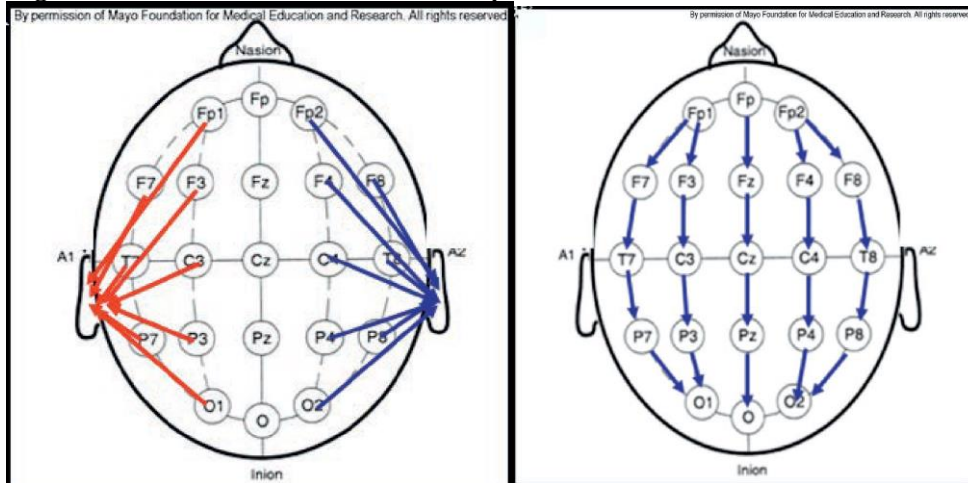
(Nidal & Malik, 2015) .



El sistema de disposición de electrodos 10-20 genera una cobertura uniforme sobre el cuero cabelludo. Se denomina "10-20" porque los electrodos están espaciados entre el 10% o el 20% de la distancia total entre un par de puntos de referencia del cráneo, la colocación de los electrodos establecidos por el sistema 10-20 es realizado como se visualiza en la Figura 5.

Estos puntos de referencia son: Nasion la raíz de la nariz, Inion en la osificación o protuberancia en el lóbulo occipital, punto auricular derecho en el oído derecho y punto auricular izquierdo del oído izquierdo. Se pueden colocar electrodos adicionales entre un par de electrodos adyacentes para localizar con mayor precisión un evento o anomalía (K. Chan, 2008).

**Figura 5** Sistema internacional de disposición de electrodos 10-20



*Nota:* Sistema internacional de disposición y colocación de electrodos 10-20 empleado en electroencefalograma (MAYO CLINIC, 2019). Nomenclatura para el Sistema 10-20, Fp Polo frontal, F frontal, T temporal, C central, P parietal, O occipital, números impares para el hemisferio izquierdo, números pares hemisferio derecho y subíndice z para línea media.


En adultos, las actividades delta y theta excesivas indican casi siempre una anomalía cerebral. El EEG de personas inconscientes está dominado por frecuencias lentas generalizadas. El EEG en enfermos epilépticos se reconoce por la presencia de potenciales en espiga (Potenciales en meseta y espigas. Son ondas de despolarización que alcanzan el umbral y dan lugar a

potenciales de acción, la estimulación simpática inhibe el desarrollo de este tipo de respuestas, mientras que el parasimpático las estimula) el registro del patrón en espiga se evidencia y se detalla en la figura 8 (Borge, 2017).

Con el sueño se vinculan dos patrones electroencefalográficos. El primero es lento (delta y theta) y se relaciona con la fase temprana del sueño. El segundo es rápido (beta) y se vincula con una etapa más tardía y profunda del sueño. Este segundo patrón se acompaña de movimientos oculares rápidos (MOR) y ensoñación; por este motivo, dicha etapa del sueño se conoce como sueño MOR (Afifi & Bergman, 2018).


La presencia de los ritmos delta y theta en adultos son indicativo de alteraciones, los ritmos delta y theta en adultos se observa en la figura 7. En la figura 6 se observa el ritmo alfa sin alteraciones, es frecuente en los periodos de niñez y pubertad.

**Figura 6** Patrón Alfa normal




*Nota: El patrón alfa aumenta en los periodos de crecimiento de la niñez a la pubertad (Afifi & Bergman, 2018).*

**Figura 7 Patrón Delta Lento**



*Nota: En los adultos las actividades de los ritmos delta y theta pueden indicar una anomalía cerebral (Afifi & Bergman, 2018).*

**Figura 8 Potencial en espiga**



*Nota: Los pacientes con epilepsia en el registro de EEG se presenta potenciales en espiga (Afifi & Bergman, 2018)*

## 7.5 Inteligencia Artificial (IA)

El término fue acuñado por John McCarthy en 1956 durante la conferencia sobre este tema. Sin embargo, la posibilidad de que las máquinas puedan simular el comportamiento humano y realmente pensar en él fue planteada previamente por Alan Turing, quien desarrolló la prueba de Turing para distinguir entre humanos y máquinas. Desde entonces, el poder de cómputo ha crecido para incluir el cómputo inmediato y la capacidad de evaluar nuevos datos en tiempo real con base en datos previamente evaluados (Yoav & Roint, 2019).

### 7.5.1 *Concepto*

Es la capacidad de las máquinas para usar algoritmos, aprender de los datos y utilizar lo aprendido en la toma de decisiones similar a un ser humano. Sin embargo, a diferencia de las personas, los dispositivos basados en IA no necesitan descansar y pueden analizar grandes volúmenes de información a la vez (Boden, 2016) (Rouse, 2021). La proporción de errores es significativamente menor en las máquinas, que realizan las mismas tareas que sus contrapartes humanas (Rouhiainen, 2018).

La IA es un campo que combina conjuntos de datos sólidos y sistemas informáticos enfocados a la resolución de problemas, estos abarcan el aprendizaje automático y profundo (IBM Cloud Education, 2020). La finalidad de los algoritmos empleados es desarrollar sistemas que realicen predicciones o clasificaciones, basados en un número de datos de entrada. El término IA se aplica a procesos realizados por un sistema que son similares con las actividades realizadas por un humano. La inteligencia abarca el aprendizaje, razonamiento, resolución de problemas, percepción y uso del lenguaje (Copeland, 2022).

### **7.5.2 Tipos de Inteligencia Artificial**

Según la unión europea se pueden clasificar en dos, en software e inteligencia artificial integrada. Los asistentes virtuales, software de análisis de imágenes, motores de búsqueda, sistemas de reconocimiento de voz y rostro, los robots, drones, vehículos autónomos e internet forman parte de los tipos de IA. (Noticias Parlamento Europeo, 2020)

Generalmente se clasifica la IA en dos formas, en algoritmos de clasificación, predicción, aprendizaje y las maquinas habilitadas para IA que poseen similitud con la mente y estructura humana.


### **7.5.3 Componentes**

Los elementos que componen la IA se discriminan en tres ramas, lógica difusa, redes neuronales artificiales y algoritmos genéticos. La lógica difusa permite analizar la información del mundo real entre una escala de falso y verdadero. Los sistemas difusos son una alternativa a las nociones de pertenencia y lógica. Las redes neuronales artificiales se basan en generalizar información extraída de datos experimentales, tablas bibliográficas o bases de datos, los cuales se determinan por expertos humanos (Ponce Cruz, 2010).

## **7.6 Interfaz Cerebro-Máquina**

Las señales cerebrales son captadas por electrodos de superficie, estos detectan picos que son leídos e interpretados por un electroencefalograma y son digitalizados para visualizarlos e interpretar el registro. En la figura 9 representa la estructura de la interfaz cerebro-maquina.

**Figura 9** Interfaz Cerebro-Máquina



*Nota:* Diagrama de bloques que representan los pasos en para la adquisición de señales en las interfaces cerebro máquina. La información se puede codificar, como las señales eléctricas del cerebro y enviarlas para proporcionar un tipo de entrada sensorial (Vidatecno.net, 2016).

## 7.7 Aprendizaje Automático

Es una técnica mediante tareas de clasificación de texto, imágenes o sonidos. Emplea una arquitectura de red neuronal. El termino profundo refiere a la cantidad de capas de la red cuyo caso corresponden a cientos de ellas. Esta técnica efectúa el reconocimiento facial, traducción de texto, reconocimiento de voz y sistemas de asistencia avanzada para un conductor. Empleando las bases del aprendizaje profundo para la rehabilitación o tratamiento a patologías por el fácil acceso del conjunto de datos, el aumento de potencia en el aprendizaje, y cuenta con modelos prediseñados (Kim, Phil, 2017).

### 7.7.1 Tipos De Aprendizaje

El aprendizaje automático pertenece a los principios de inteligencia artificial, esto hace referencia a procesos de aprendizaje automáticos de los sistemas de programación, lo cual genera mejores resultados en menos tiempo (Marsland, 2015).

El aprendizaje supervisado es una modalidad de Machine Learning que se podría entender como algoritmos que “aprenden” de los datos introducidos por una persona. En este caso: Se necesita la intervención humana para etiquetar, clasificar e introducir los datos en el algoritmo. (Kim, Phil, 2017).

El aprendizaje no supervisado es un método de aprendizaje automático donde un modelo se ajusta a las observaciones. Se distingue del aprendizaje supervisado por el hecho de que no hay un conocimiento anticipado, en este el conjunto de datos de objetos de entrada es tratado. (Kim, Phil, 2017). El aprendizaje semi-supervisado, es una clase de técnicas de aprendizaje automático que utiliza datos de entrenamiento tanto etiquetados como no etiquetados: normalmente una pequeña cantidad de datos etiquetados junto a una gran cantidad de datos no etiquetados. (Kim, Phil, 2017).

## **7.8 Algoritmos de regresión**

Se ocupan del modelado de la relación entre las variables. Esta relación se refina iterativamente con la ayuda de una medida de error en las predicciones o la probabilidad que logra el modelo. A menudo funcionan sobre análisis estadísticos (Sullivan, 2017).

Es un método estadístico para modelar la relación entre una variable dependiente e independiente con una o más variables independientes. Comprende cómo cambia el valor de la variable dependiente correspondiente a una variable independiente cuando otras variables independientes se mantienen fijas. Predice valores continuos o reales (Jaiswal, Sonoo, 2021). En el aprendizaje automático mediante algoritmos de regresión se emplean: árboles de decisión, bosques aleatorios, máquinas de soporte vectorial y redes neuronales.

### **7.8.1 Árboles de decisión**

Técnica de minería de datos, que divide de forma recursiva la información basada en la cantidad aproximada de datos agrupados o por aproximación de primer alcance, generando

subdivisiones de nodos, partiendo de una tendencia principal la cual, generando divisiones en las tendencias usando las medidas más puras teniendo un proceso estadístico. Tiene como herramienta de mejoramiento a la generación del primer árbol la poda que permite optimizar la cantidad de bifurcaciones usadas para clasificar o hacer regresión (Anyanwu, Matthew & Shiva, S, 2009). Los árboles de decisión forman parte de los algoritmos de aprendizaje supervisado con una variable de objetivo predefinida, permite predecir el valor salida mediante los datos de entrada (Francois & Allaire, 2017) .

### **7.8.2 *Bosques aleatorios***

Técnica basada en los árboles de decisión, en la cual cada árbol depende de una colección de variables al azar, constituyendo un vector de varias dimensiones representando, la entrada de un valor o real y obteniendo un valor o variable de salida predicha a partir del proceso estadístico de división del conjunto de árboles agrupado (Kumar Chinnamgari, 2019).

### **7.8.3 *Máquinas de soporte vectorial***

Herramienta de resolución de problemas, función de estimación multidimensional, para el reconocimiento de patrones y tomas de decisión y una buena capacidad de generalización no dependiente de modelos matemático-estadísticos, en su lugar usa modelos algebraicos geométricos para la división de los datos generando vectores de predicción o clasificación (Vapnik, Golowich, & Smola, 1996)

### **7.8.4 *Redes neuronales***

Modelo que surge de la mezcla de la ciencia de la computación y la estadística, como método que permite el reconocimiento de patrones por la abstracción de estos, siendo un método altamente usado en la ingeniería biomédica. Teniendo como factor fundamental la ponderación de características, por medio de la agregación de perceptrones como validación para aceptar o no



basado en el peso de la variable que ingrese, de la misma forma generar preferencia de los valores por medio de la suma de la componente bias (Ciaburro & Venkateswaran, 2017).

## 7.9 Métricas de Evaluación

Todas las técnicas utilizadas se validan contra métricas, que pueden mostrar la proximidad de cada modelo para hacer predicciones correctas, basadas en las propiedades de cada modelo y mostrar cómo replicar más cerca de la variable de respuesta solicitada. Los criterios comúnmente utilizados para marcar predicciones correctas son:

***Mean Squared Error:*** Es una métrica de evaluación de modelos, que se utiliza a menudo con modelos de regresión. El error cuadrático medio de un modelo, con respecto a un conjunto de prueba es la media de los errores de predicción cuadráticos en todas las instancias del conjunto de prueba. El error de predicción es la diferencia entre el valor real y el valor previsto para una instancia (Sammut & Webb, 2010). Definida como una comparación de la suma de la matriz de resultado no negativa y los coeficientes, la predicción se valida contra la media de la matriz considerada variable Y, y la suma de todas las diferencias entre los valores es formado. El valor real que indica el valor obtenido y el error acumulado de las variables pronosticadas (Theobald, 1974).

***Squared Error ( $R^2$ ):*** Utilizada para generar descripción del desempeño del modelo de regresión, que denota la efectividad del modelo en cuanto a la predicción conforme el resultado del modelo se acerca a 1. El error al cuadrado es una función de pérdida común utilizada en procesos de regresión es el cuadrado de la diferencia entre los valores predicho y verdadero. (Sammut & Webb, 2010)

**Root mean square error:** Estándar de medida utilizado para evaluar el rendimiento de un modelo, para denotar el arreglo o desarreglo. Es la desviación estándar de los errores de predicción. Los residuos son una medida de qué tan lejos están los puntos de datos de la línea de regresión; El error cuadrático medio, se usa comúnmente en análisis de regresión para verificar resultados experimentales (Glen, 2019).

**Root mean logarithmic square error (RMSLE):** Métrica utilizada para denotar la predicción realizada por un modelo generando la sumatoria de esta como un error asociado acumulativo porcentual penalizando errores pequeños y usando en un amplio rango de variables (Dua, Ghotra, & Pentreath, 2017). Cuando el valor de RMSLE es más pequeño más cercano se encuentra el vector de valores de predicción al vector de valores reales (Liu, y otros, 2020).

Para determinar el tiempo de ejecución de cada algoritmo empleado se usa un cronometro integrado en el código. Generalmente, el tiempo del usuario (user) se relaciona con la ejecución del código, el tiempo del sistema (system) se relaciona con procesos del sistema tales como abrir y cerrar archivos, y el tiempo transcurrido (elapsed) es la diferencia en tiempos desde que inició la ejecución hasta su finalización.” (Burns, 2011)

## 8. Metodología

Se escoge el conjunto de señales para la parametrización y caracterización del área motora cerebral, con las especificaciones de tiempo, características ambientales que establecen si el registro de la señal no es afectado por incertidumbre de tipo aleatorio o sistemático.

Para el estudio se cuenta con un banco de señales realizadas previamente con protocolos experimentales, donde se relacionan funciones de tipo neuromuscular, de aprendizaje, estrés y miedo.

### 8.1 Origen de las señales de EEG procesada

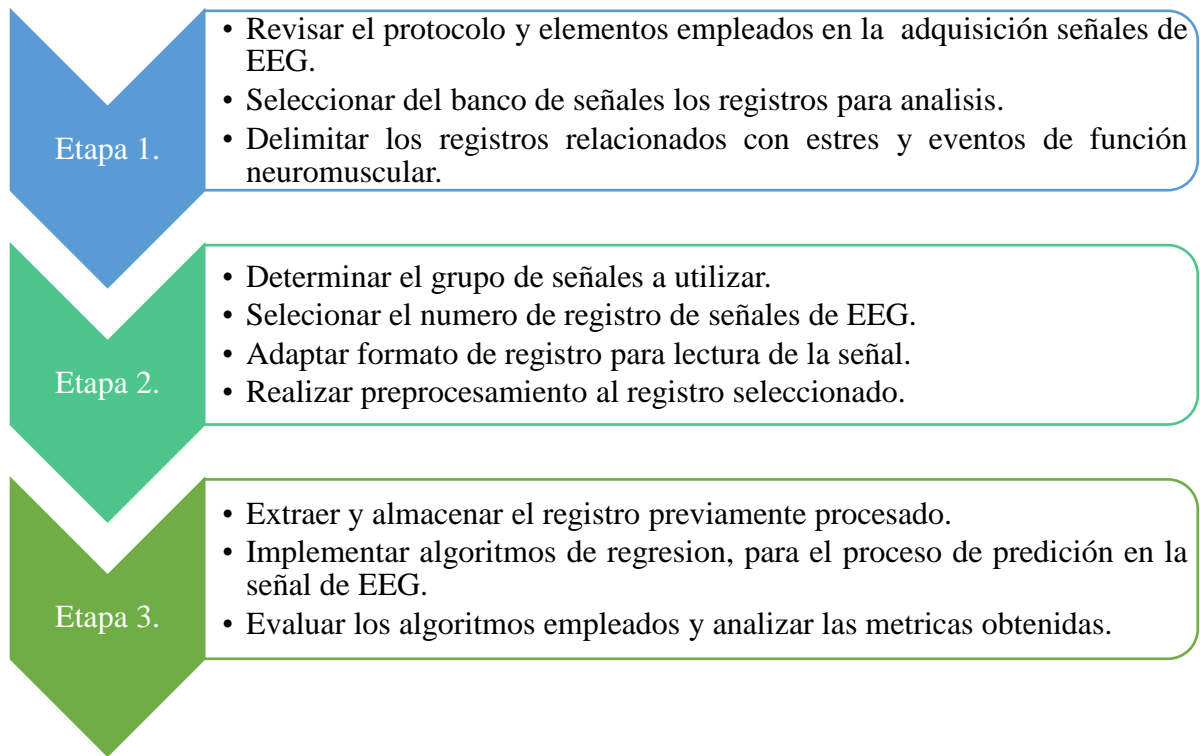
El experimento con el cual se obtuvieron las señales se desarrolló evitando movimiento que introdujera de ruidos de artefacto que por contacto o señales musculares intervengan en el proceso de detección de señales cerebrales y permitiera obtener señales y frecuencias tipo beta y beta 2 por procesos de aprendizaje neuromotor, así se pudiera establecer si los pacientes podían generar redes nuevas y cuáles son las señales que el cerebro procesa en interconexiones en la ejecución de acciones no rutinarias.

La adquisición de las señales las realizó en sesiones diferentes, con pacientes diferentes con mismo escenario y mismas condiciones para la reproducibilidad y repetibilidad del ejercicio: Emplearon diadema de electroencefalografía inalámbrica epoc emotiv plus de 14 canales con programa de análisis Xavier como sistema de recopilación de señales electroencefalográficas. Se usa dron Dji Phantom 2.

Computador portátil a distancia no mayor de 5 metros del paciente para la recepción de señales  
Área no mayor a 16 metros cuadrados.

La figura 10 representa los componentes de la metodología clasificados en tres etapas, con actividades específicas realizadas.

**Figura 10** Componentes de metodología




*Nota. El diagrama fragmentado por tres etapas determina las actividades realizadas en cada una respectivamente, en el proyecto de investigación realizado.*

## **8.2 Delimitación de grupo de señales a utilizar**

Se determina el grupo de señales a utilizar, que intervienen en los procesos neuromotor. Los sensores Fp1, Fp2, F7, F3, Fz, F4 y F8 están relacionados con las funciones de razonamiento, habla, control de movimiento, emociones y resolución de problemas. Sensores C3, Cz y C4 funciones sensoriomotor. P3, Pz Y P4 atención, percepción y procesamiento de los estímulos. T3, T5, T6 y T4 con la memoria y audición. Sensores O1 y O2 funciones visuales. La relación de funciones y sensores se observa en la figura 11.

**Figura 11** Relación entre sistema estandarizado de colocación de electrodos 10-20 y las funciones



*Nota.* Se representa las funciones del cerebro por área y su equivalente con el sistema de electrodos 10-20. (Bitbrain, 2020)

El grupo de señales son determinadas con relación a funciones de la corteza neuromotora, los sensores localizados en el área de estudio son: AF4, F4, F8 y FC6.

La cercanía de las señales mediante los sensores permite interpretar la interacción de estas, en función de la memoria y motricidad fina, donde intervienen los lóbulos frontales y prefrontales en procesos de aprendizaje, razonamiento, resolución de problemas, memoria y control de movimiento.

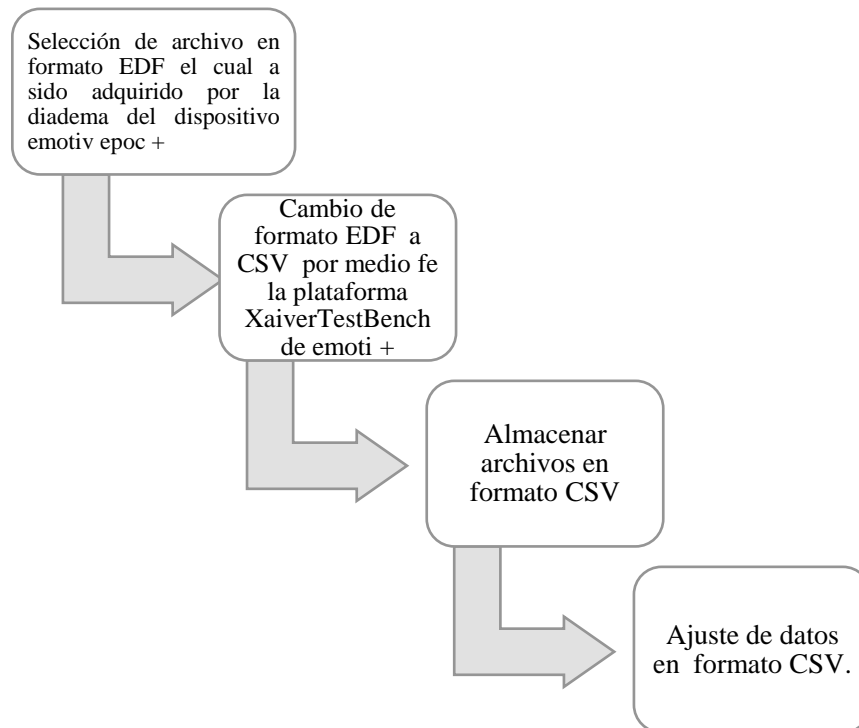
### 8.3 Preprocesamiento

Las señales son procesadas previo al uso de los métodos de regresión haciendo normalización de la señal.

Se realiza ajuste al formato del registro de los datos almacenados para el uso en la interfaz con el lenguaje de programación R. En la figura 12 se identifican los pasos para el procesamiento de

los datos de EEG. El ajuste de los datos en el formato CSV consiste en determinar el formato a un valor numérico, para que la interfaz de programación reconozca los valores en forma de número.

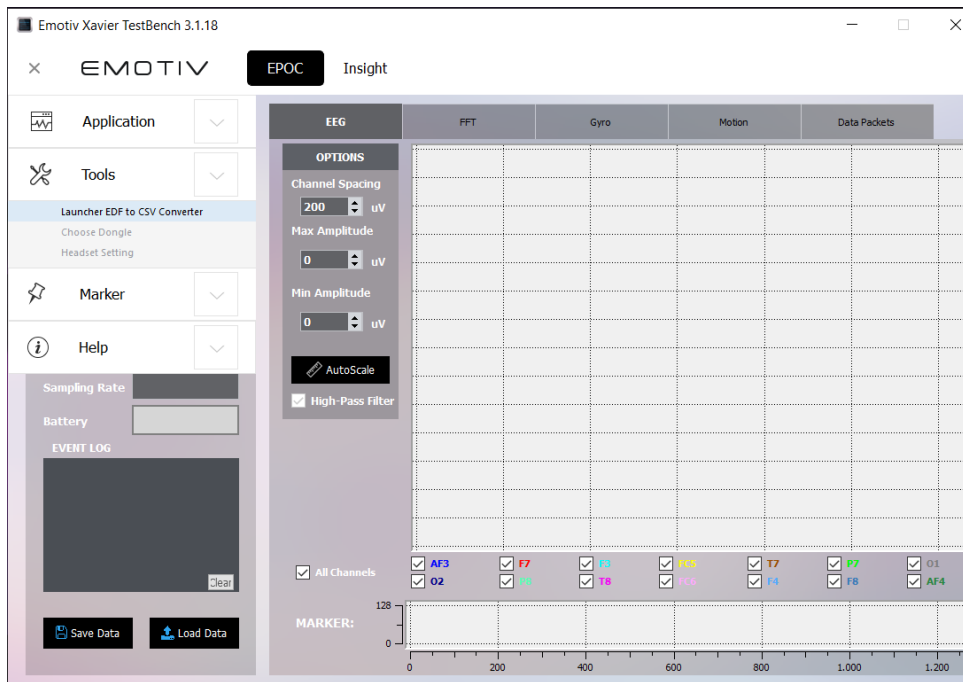
**Figura 12** Preprocesamiento de datos



*Nota. Diagrama de actividades realizadas para el cambio de formato de EDF a CSV y normalización, realizado por Autores.*

Se toman los datos en formato EDF y se convierten en formato CSV, debido a inconvenientes con la carga de archivos que impiden su correcta lectura y proceso de los datos para la generación de la predicción realizado en la siguiente imagen. Para esto se usa la aplicación de emotiv Xavier testbench como se visualiza en la figura 13.

**Figura 13** Conversión de datos de EDF a CSV



*Nota.* Visualización de aplicativo para realizar el proceso de conversión de formato de EDF a CSV.

Las características de la señal presentan voltaje offset de 4100  $\mu\text{V}$ , para evitar valores negativos, los datos se presentan con un exponencial de  $1e21$  lo cual genera datos de gran tamaño. Los datos tienen una frecuencia de muestreo de 128Hz. En la red neuronal se realiza un proceso de normalización de los datos en una escala de 0 a 1.

El formato de datos europeo (EDF) es un formato simple y flexible para el intercambio y almacenamiento de señales físicas y biológicas, diseñado por ingenieros médicos usado principalmente en exámenes de análisis continuo del sueño (Alvarez Estevez, 2019). Estos archivos requieren de exploradores específicos, para visualizar los datos. Debido a esto se realiza un cambio previo al formato mediante la plataforma XavierTestBench de emotiv+, obteniendo un archivo más sencillo para cargar en el programa R, para realizar la predicción con los algoritmos.

Un archivo CSV (valores separados por comas) es un archivo de texto que tiene un formato específico que permite guardar los datos en un formato de tabla estructurada. Los archivos CSV sirven para manejar una gran cantidad de datos en formato tabla, sin que ello conlleve sobrecoste computacional alguno (López, 2020).

Al cargar los datos convertidos del formato EDF a CSV presentan más títulos que columnas debido a la información concerniente a pacientes, frecuencia de muestreo, número de canales, se realiza la supresión de los títulos de las columnas no necesarios para emparejar tanto títulos como columnas en el formato CSV.

Las columnas hacen referencia a los potenciales bioeléctricos de constitución bipolar y promediadas, dentro de las cuales se utilizan todas las señales, pero deben omitirse de antemano para valores cero o potenciales (desventaja de las señales promediadas debido a que las neuronas están correlacionadas porque su tensión puede cancelar valores debido a amplitudes iguales).

#### **8.4 Entrenamiento de algoritmos**

Entrenamiento de algoritmos de aprendizaje automático: Se usan diferentes tipos de algoritmos, árboles de decisión, bosques aleatorios y máquinas de vector soporte para verificar cual puede ser el método que ofrezca mejores resultados en el proceso de regresión.

##### ***Árboles de decisión***

El árbol de regresión es un subtipo de árbol de predicción que se aplica cuando las variables de respuesta son continuas. En general, cuando se entrena un árbol de regresión, las observaciones se distribuyen a través de ramas (nodos) que crean la estructura del árbol hasta llegar a los nodos terminales. Cuando se pronostica una nueva observación, el árbol se recorre según el valor del predictor hasta llegar a uno de los nodos terminales. La predicción del árbol es la respuesta promedio de las observaciones de entrenamiento en el mismo nodo terminal (Amat Rodrigo,



2017). Se estima un parámetro de penalización de  $K=10$  y desviación media residual en un rango de 10. Se garantiza al menos 2 divisiones de los datos en cada paso del entrenamiento.

### ***Bosques Aleatorios***

Las regresiones que usan bosques aleatorios significan la construcción fortuita de muchos árboles de decisión en el mismo conjunto de datos, y las decisiones finales regresión calculan el promedio de las predicciones proporcionadas por cada uno de los árboles que constituyen el bosque (Delgado, 2018). Como parámetros se realiza la selección de 500 y 100 arboles para el proceso de bosques aleatorios.

### ***Máquinas de Soporte Vectorial***

Son modelos capaces de generar regresiones de datos no lineales a partir de la transformación de los datos de entrada. Busca ajustar los datos, garantizando que la separación entre ésta y ciertos valores específicos del conjunto de entrenamiento (los vectores de soporte) sea la mayor posible

Evaluación de los modelos: Los resultados obtenidos son evaluados por medio de métricas para contar la efectividad, exactitud y precisión del algoritmo (Delgado, 2018).

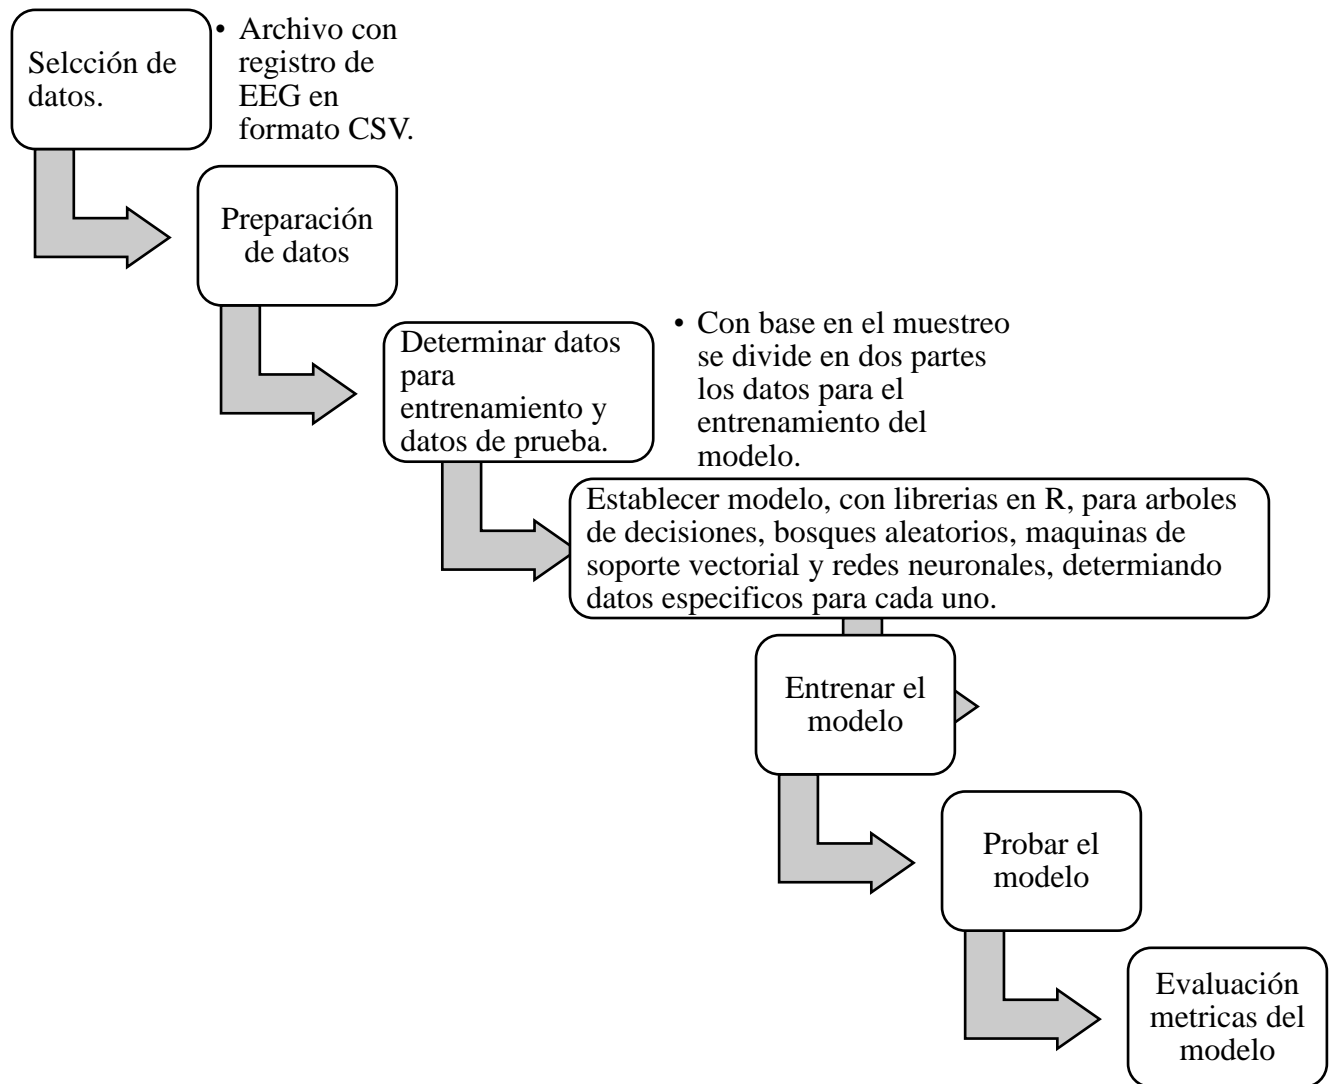
parámetros SVM-Type: eps-regression , SVM-Kernel: linear, cost: 1, gamma: 0.1666667, épsilon: 0.1, Número de vectores de soporte 4776

### ***Redes Neuronales***

Las redes neuronales artificiales tienen la capacidad de aprender la relación compleja entre las características y el objetivo, debido a la presencia de la función de activación en cada capa.

La figura 14 representa el ciclo de vida y las principales etapas del aprendizaje supervisado (aprendizaje maquina) empleado en los procesos de regresión.

**Figura 14** Aprendizaje Supervisado por metodo de regresión



*Nota. El diagrama representativo de las principales etapas en aprendizaje supervisado empleando regresión, Autores.*

Los procesos relacionados a las señales se realizaron por medio de la interfaz de programación en R versión 4.2.0, mediante un computador portátil, se utilizó por su capacidad de almacenamiento de los datos de EEG, RAM capacidad media de 8GB, velocidad del procesador de 2.2GHZ, y tarjeta GPU en caso de necesitar capacidad extra de procesamiento para la ejecución de algoritmos.

## 9. Resultados

### 9.1 Preprocesamiento de los Datos

Los datos almacenados de EEG por la diadema *emotiv epoc +* en el formato EDF, para un mejor rendimiento se convierten en formato CSV como se visualiza en la tabla 4, los datos visualizados presentan un voltaje offset de 4100  $\mu\text{V}$ , para evitar valores negativos, los datos se presentan con un exponencial de 1e21 lo cual genera datos de gran tamaño. Las columnas hacen referencia a los potenciales bioeléctricos, en los canales respectivos. Los datos tienen una frecuencia de muestreo de 128Hz. Para la interpretación de los datos se realizó la conversión de frecuencia de muestreo a segundos mediante la siguiente ecuación

$$t(s) = \frac{1}{f} \quad t(s) = \frac{1}{128\text{Hz}} = 0.0078125 \text{ s}$$

**Tabla 4** Datos convertidos de EDF a CSV

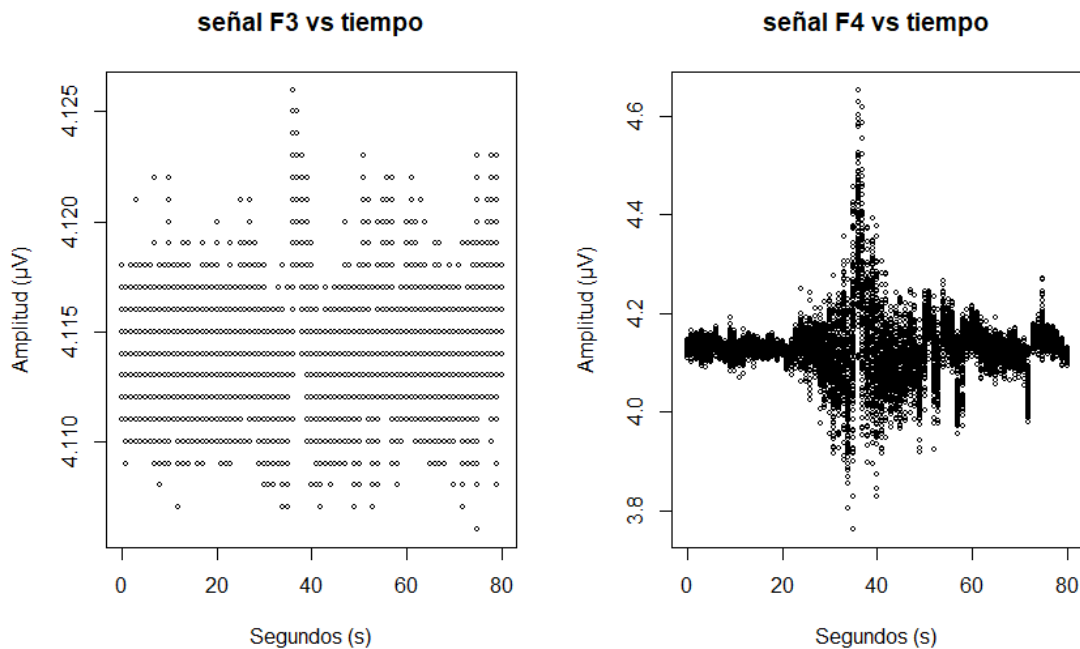
| muestra | AF3     | F7      | F3      | FC5     | T7      | O2      | FC6     | F4      | AF4     |
|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|
| 1       | 4113.00 | 4115.00 | 4117.00 | 4126.00 | 4108.00 | 4124.00 | 4124.00 | 4148.00 | 4134.00 |
| 2       | 4093.00 | 4097.00 | 4112.00 | 4111.00 | 4091.00 | 4117.00 | 4111.00 | 4131.00 | 4117.00 |
| 3       | 4088.00 | 4094.00 | 4114.00 | 4108.00 | 4089.00 | 4116.00 | 4110.00 | 4129.00 | 4114.00 |
| 4       | 4096.00 | 4097.00 | 4116.00 | 4108.00 | 4090.00 | 4115.00 | 4109.00 | 4130.00 | 4117.00 |
| 5       | 4100.00 | 4102.00 | 4115.00 | 4110.00 | 4102.00 | 4118.00 | 4106.00 | 4127.00 | 4118.00 |
| 6       | 4095.00 | 4102.00 | 4114.00 | 4110.00 | 4104.00 | 4116.00 | 4102.00 | 4123.00 | 4115.00 |
| 0       | 4106.00 | 4111.00 | 4113.00 | 4122.00 | 4107.00 | 4113.00 | 4109.00 | 4130.00 | 4123.00 |
| 128     | 4108.00 | 4111.00 | 4113.00 | 4122.00 | 4110.00 | 4113.00 | 4109.00 | 4129.00 | 4118.00 |
| 127     | 4109.00 | 4118.00 | 4115.00 | 4125.00 | 4122.00 | 4124.00 | 4117.00 | 4135.00 | 4126.00 |
| 126     | 4106.00 | 4115.00 | 4115.00 | 4125.00 | 4120.00 | 4126.00 | 4123.00 | 4139.00 | 4131.00 |
| 125     | 4107.00 | 4110.00 | 4113.00 | 4128.00 | 4122.00 | 4123.00 | 4119.00 | 4137.00 | 4127.00 |

*Nota. Datos tomados del formato CSV en Excel, Autores.*

Con los datos ajustados en el formato CSV se cargan en el lenguaje de programación R para realizar el proceso de predicción con los algoritmos de inteligencia artificial. Se excluyen los datos nulos.

Se grafica mediante la función par para realizar la visualización de la señal del lóbulo frontal del hemisferio derecho y del hemisferio izquierdo, relacionada con la función neuromotora esta grafica se muestra en la figura 15.

**Figura 15** Comparación de señales F3 y F4 originales, para la predicción



*Nota. Grafica tomada de Rstudio por Autores. Señal comparativa, grafica tipo puntos.*

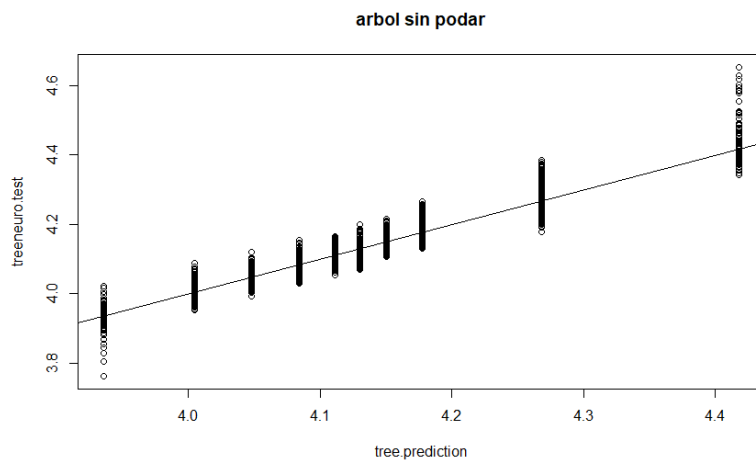
La motricidad fina está relacionada con la memoria motora, en la corteza neuromotora primaria, por lo cual la variable a predecir es F4 ubicada en el lóbulo frontal derecho.

## 9.2 Algoritmos de Regresión

### 9.2.1 Árboles de decisión

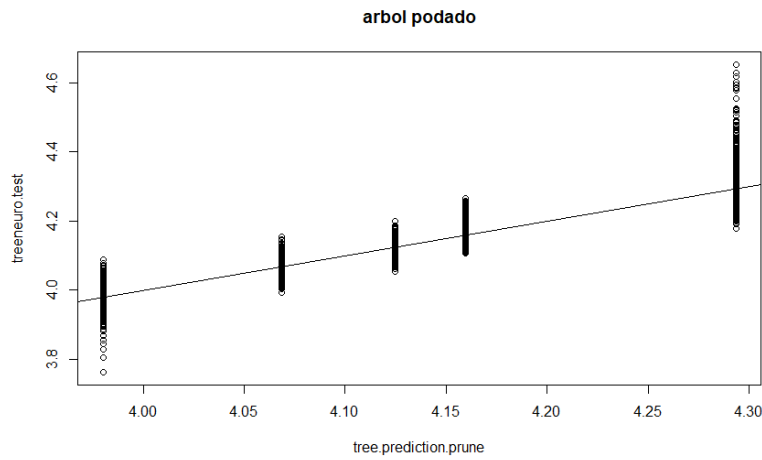
El algoritmo de árboles de regresión genera la división del registro de las covariables de entrada para entrenamiento y datos para evaluación. Se toman el registro de las covariables y la variable a predicción (F4) y las métricas correspondientes para evaluar la predicción y comportamiento de los datos empleados, en las figuras 16 y 17 se observa cuanto se alejan los resultados de la recta prospectada.

**Figura 16** *Árbol de decisión sin podar de 10 ramas*



*Nota. Grafica tomada de Rstudio, por Autores.*


Figura 17 Árbol podado de 5 ramas



Nota. Grafica tomada de Rstudio, por Autores.

En La evaluación de los árboles de decisión, se observa inicialmente un error medio cuadrado de 0.0064, con un árbol de decisión inicial de 10 ramas y un error cuadrado de 0.0800. Con la poda del árbol “La poda consiste en eliminar divisiones de nivel inferior que no contribuyen significativamente a la precisión del árbol. (IBM, 2021)” se genera un error medio cuadrado de 0.0060 y un error cuadrado de 0.0273. El árbol de decisión sin podar se observa en la figura 18.

Figura 18 Árbol de decisión sin poda




Nota. Grafica tomada de Rstudio, por Autores

Se realizo la poda del árbol de decisión, pasando de 10 divisiones a 5 divisiones, para eliminar las divisiones inferiores con menor relevancia en el proceso de predicción, esto se refiere

a emplear los nodos principales para el algoritmo de predicción, verificando las covariables, que son los sensores cercanos a F4 y el de mayor relevancia para la predicción, para el modelo de predicción de la variable F4. El árbol de decisión podado se observa en la figura 19.

**Figura 19** *Árbol de decisión podado*

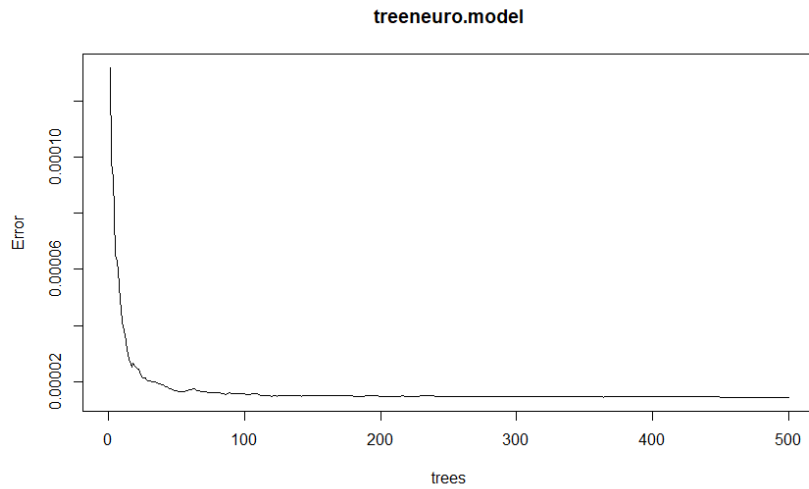


*Nota. Grafica tomada de Rstudio, por Autores.*

### 9.2.2 Bosques Aleatorios

Se realiza regresión por bosques aleatorios iniciando con 500 árboles y se reduce a 100 árboles observando en las gráficas la variación en cada opción. Se grafica la curva de error medio cuadrado la cual se muestra en la figura 20, denotando agrupación en un rango de 100 de árboles. Basado en el método práctico del codo o agrupamiento se determina la cantidad probable de árboles a emplear, mejorando el desempeño en el proceso de regresión, tomando como valor óptimo de 100 árboles.

**Figura 20** Curva bosques aleatorios vs error

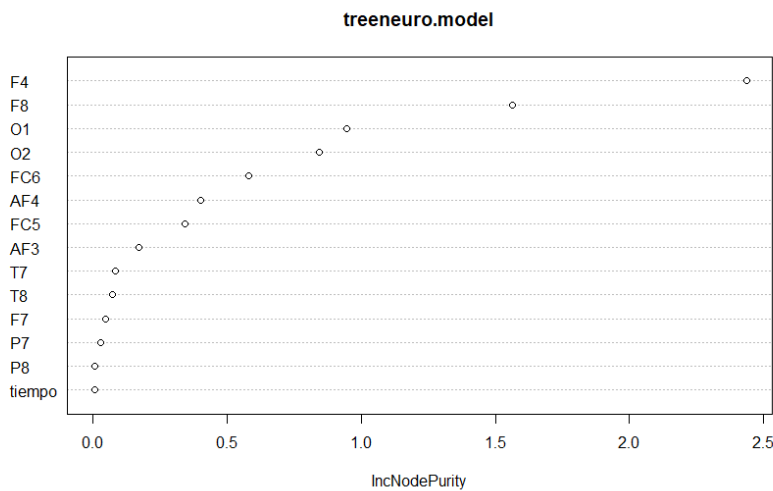


*Nota. Grafica tomada de Rstudio, por Autores.*

Las variables de importancia del modelo de predicción se observan en la gráfica de índice de nodos de pureza, las señales más preponderantes, mostrando las características de mayor peso, para predecir en este caso la señal F4, con error cuadrático medio de 7.18 y variabilidad de 98.27%.

Las variables preponderantes se observan en la figura 21.

**Figura 21** Señales Preponderantes




*Nota. Grafica tomada de Rstudio, por Autores.*



Se reviso la relación entre los datos de entrenamiento y los datos para el modelo de predicción de bosques aleatorios, para identificar la afinidad del modelo. La señal original (azul) y la señal predicha (roja) se muestra en la figura 22.

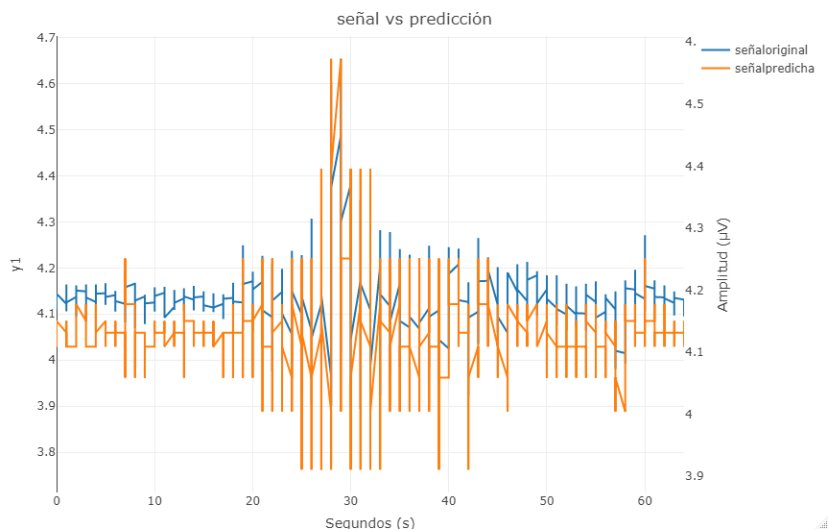
**Figura 22** Señal comparativa



*Nota. Grafica tomada de Rstudio, por Autores.*

El comportamiento del modelo se observa en la figura 23 donde se relacionan la señal original de F4 versus la señal de predicción por bosques aleatorios.

**Figura 23** Comparativo de señal original vs predicción




*Nota. Grafica tomada de Rstudio, por Autores.*

### 9.2.3 Máquina de Soporte Vectorial

Se realiza regresión con el método de máquina de soporte vectorial con el registro de EEG, con 10240 datos y 15 variables. La señal para predecir que es la variable F4 pertenece al hemisferio derecho, por lo cual se emplean las variables cercanas a F4 del hemisferio derecho ubicadas en el lóbulo frontal y límites cercanos, los canales empleados para la predicción son: AF4, FC6, T8, P8, F8 y O2. Presenta un error entre la señal de predicción y la señal original de 0.0086 y un error medio cuadrado de 0.9788. El modelo se reduce a las señales específica en 4776 vectores de soporte. En el procedimiento para mejorar el modelo, con la función tune se obtiene un error entre la predicción y la señal original de 0.0175 y un error medio cuadrado de 0.0016. La figura 24 representa la comparación del modelo de regresión con máquina de soporte vectorial y la señal original de F4.

**Figura 24** Comparativo de puntos entre predicción y original




*Nota. Grafica obtenida de Rstudio. Autores.*

### 9.2.4 Red Neuronal


Se realizo una red neuronal con 10 neuronas con la finalidad de encontrar y comprobar las métricas. Con suma de error cuadrático de 0.0001, error cuadrático logarítmico de 0.0021, y un error cuadrático medio de 0.0111, la estructura de la red neuronal resultante se muestra en la figura 25, y en la figura 26 se observa la suma de error cuadrático entre la señal real versus predicción.

**Figura 25 Real vs predicción**



*Nota. Grafica tomada de Rstudio, por Autores.*

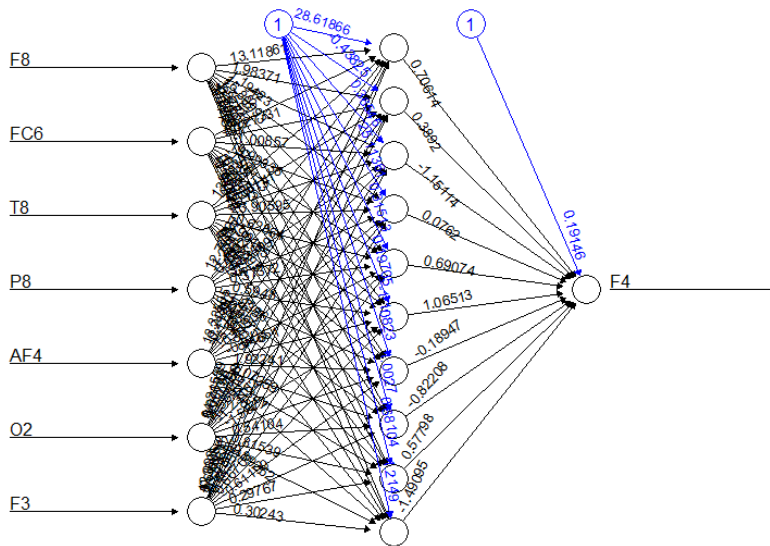
**Figura 26 Red neuronal con 10 neuronas**



*Nota. Grafica tomada de Rstudio, por Autores.*

Se realiza una red neuronal de 10 neuronas, con señales de entrada del hemisferio derecho y F3, genera error cuadrático logarítmico de 0.0110, y un error cuadrático medio 0.0561, la estructura de la red neuronal resultante se muestra en la figura 27.

**Figura 27** Red neuronal con entradas de sensores hemisferio derecho



*Nota. Grafica tomada de Rstudio, por Autores.*

### 9.2.5 Tiempo de ejecución de procesos en R

Para evaluar el tiempo empleado y analizar qué modelo de regresión, requiere un menor gasto computacional se visualizan los tiempos empleados, en la tabla 5.

**Tabla 5** Tiempo de ejecución de modelos de regresión en R

| Modelo                        | User Time | System time | Elapsed time |
|-------------------------------|-----------|-------------|--------------|
| Árboles de decisión.          | 2.36      | 3.92        | 6.80         |
| Bosques aleatorios.           | 43.47     | 3.80        | 48.37        |
| Máquina de soporte vectorial. | 35.52     | 3.92        | 40.36        |
| Red neuronal 1.               | 144.81    | 2.30        | 150.94       |
| Red neuronal 2.               | 5.51      | 0.52        | 7.23         |

*Nota. La tabla representa el tiempo empleado, en cada modelo de regresión para la predicción. Autores.*

### 9.2.6 Comparación evaluación de métricas algoritmos de regresión

Al construir un modelo de regresión, estamos intentando reducir el error que comete un algoritmo. Para ello, seleccionamos una función para medir el error. Las métricas de aprendizaje automático empleadas para la clasificación, como la precisión, no se aplican a la regresión. En su lugar, usamos métricas diseñadas para analizar valores. En la tabla 6 se representa la evaluación de los errores presentados en cada algoritmo usado.

**Tabla 6 Métricas de Evaluación**

| Modelo                        | R2     | MSE    |
|-------------------------------|--------|--------|
| Árboles de decisión.          | 0.0060 | 0.0273 |
| Bosques aleatorios.           | 0.0156 | 7.18   |
| Máquina de soporte vectorial. | 0.0175 | 0.0016 |
| Red neuronal 1.               | 0.0001 | 0.0111 |
| Red neuronal 2.               | 0.0016 | 0.0561 |

*Nota. La tabla representa la evaluación por medio del error cuadrático y el error cuadrático medio, en cada modelo de regresión para la predicción. Autores*

## 10. Discusión

Los resultados evidencian el grado de eficiencia del modelo para los cuales adicionalmente se analizan con otras métricas para determinar el grado de precisión del modelo, para ello se verifica con la métrica  $R^2$  debido a su eficacia para determinar la desviación residual (Cameron & Windmeijer, 2012) y como indicador el cual precisa que los valores se encuentran entre cero y uno siendo uno indicador de precisión del modelo y variabilidad de las predictores y conjunto con el error medio cuadrado se encuentre dentro de la desviación estándar y nuevamente se prueban los algoritmos para corroborar los datos previamente obtenidos.

Los resultados previos permiten evidenciar la eficiencia de los modelos de predicción, donde se analizan, mediante métricas de error cuadrático para determinar la precisión del algoritmo. Los valores se encuentran entre un rango de cero y uno, siendo un indicador de precisión.

En el algoritmo de árboles de decisión, se encuentran valores de error cuadrado de 0.08009841 para el árbol de 10 ramas y un error cuadrado de 0.0273 para un árbol de 5 ramas, se evidencia la efectividad del modelo de regresión, en el grafico se generan réplicas de puntos en la señal de predicción versus la señal original.

Para el modelo de bosques aleatorios el mejor resultado se presenta con el uso de 100 árboles, con un error cuadrático medio de 7.18 y varianza de 98.27%. Observando y analizando las gráficas de las señales de predicción hay generación de replicas sobre los puntos reales encima y debajo de ellos y ente la señal predicha y la señal original se presentan en replicas paralelas. La variable preponderante en el proceso está relacionada con la señal del sensor F8 que aumenta la tendencia de predicción frente a la señal F4.

En el modelo de regresión median máquina de soporte vectorial, tiene un error cuadrado medio de 0.9788 y un error en predicción de 0.0086, de igual forma se presentan réplicas de puntos

de la señal predicha, pero se observa una disminución de estos, se emplea un menor proceso en las máquinas de soporte vectorial.

El modelo aplicado con redes neuronales mostro una mejora, con valores de suma de error cuadrático de 0.0001, error cuadrático logarítmico de 0.0021, y un error cuadrático medio de 0.0111, aunque el proceso requiere más tiempo, para realizar el procesamiento de los datos y generación del modelo, infiere el número de señales de entrada y las capas internas empleadas.

Actualmente la comparación de los resultados obtenidos para los procesos de reconstrucción y predicción de señales fisiológicas por método de regresión, no se pueden comparar debido a la carencia de trabajos de investigación relacionados con el tema. Se encuentran trabajos similares en la minería de datos para la bolsa de valores, en procesos de predicción mediante variables monetarias.

## 11. Conclusiones

Empleando las señales del hemisferio derecho y hemisferio izquierdo simultáneamente y el uso de señales específicas de un hemisferio referente a la señal de predicción, se evidencia una mejora en el uso de mayor número de datos empleados como entrada para los modelos de regresión enfocados en la predicción.

En modelos de regresión con árboles de decisión, la variable preponderante está situada en lóbulo frontal, F8 para la predicción de la señal F4, esto se relaciona con la cercanía de los sensores, la similitud de las áreas de Brodmann en función de movimientos finos y funciones motoras.

Por velocidad de respuestas los algoritmos de regresión mediante máquinas de soporte vectorial, permite un procesamiento de los datos en un menor tiempo. Dentro de las desventajas se precisa la generación de réplica de puntos entre las señales original y de predicción, en los diferentes cuadrantes de la gráfica. No obstante, no permite determinar las variables de mayor importancia dentro del proceso de regresión.

Por velocidad y menor tiempo de ejecución de los árboles de decisión y máquinas de soporte vectorial permite el trámite de las señales mucho más rápido. Dentro de los puntos de desventajas que presenta el modelo está la generación de réplicas y despolarización de las gráficas. La predicción por redes neuronales presenta un menor rango de error, requiere un tiempo mayor en la ejecución.

La reconstrucción de la señal de EEG permitió denotar la posibilidad de reproducir señales basada en áreas adyacentes, observando la viabilidad con cada algoritmo de regresión. Esto ayuda en los estudios posteriores de patologías y en posible integración de la señal en sistemas neuronales.



## 11. Bibliografía

- Adhikaria, B., Epstein, B., & Dhamala, M. (2017). Enhanced brain network activity in complex movement rhythms: a simultaneous fMRI-EEG study. *Brain Connectivity*, 1-40. doi:10.1089/brain.2017.0547)
- Afifi, A., & Bergman, R. (2018). *Neuro Anatomía Funcional*. Mc Graw Hill.
- Alvarez Estevez, D. (2019). *European Data Format*. (EDF PLUS) Obtenido de European Data Format: <https://www.edfplus.info/>
- Amat Rodrigo, J. (Febrero de 2017). *Árboles de decisión, random forest, gradient boosting y C5.0*. Obtenido de Ciencia de datos: [https://www.cienciadedatos.net/documentos/33\\_arboles\\_de\\_prediccion\\_bagging\\_random\\_forest\\_boosting#%C3%81rboles\\_de\\_regresi%C3%B3n](https://www.cienciadedatos.net/documentos/33_arboles_de_prediccion_bagging_random_forest_boosting#%C3%81rboles_de_regresi%C3%B3n)
- American Heart Association. (2021). Heart Disease and Stroke Statistics 2021 Update. doi:10.1161/CIR.0000000000000950
- Anyanwu, Matthew & Shiva, S. (2009). Comparative Analysis of Serial Decision Tree Classification Algorithms. *International Journal of Computer Science and Security*., 230-239. Obtenido de [https://www.researchgate.net/publication/41822936\\_Comparative\\_Analysis\\_of\\_Serial\\_Decision\\_Tree\\_Classification\\_Algorithms](https://www.researchgate.net/publication/41822936_Comparative_Analysis_of_Serial_Decision_Tree_Classification_Algorithms)
- Benjamin EJ, Blaha MJ, Chiuve SE, Cushman M, Das SR, Deo R, . . . Gillespie C Isas. (Enero de 2017). Heart Disease and Stroke Statistics 2017. *AHA JOURNALS*(133), 447- 454.
- Bitbrain. (30 de Abril de 2020). *Colocación de electrodos EEG en un Layout Fijo vs. Variable*. (Neurotecnología) Obtenido de <https://www.bitbrain.com/es/blog/colocacion-electrodos-eeeg>
- Boden, M. (2016). *Inteligencia Artificial*. Turner Noema.
- Borge, J. N. (12 de Junio de 2017). *Universidad de Cantabria, Tema 2. Motilidad del tracto intestinal*. Obtenido de <https://ocw.unican.es/mod/page/view.php?id=565#:~:text=Potenciales%20en%20meseta%20y%20espigas,que%20el%20parasimp%C3%A1tico%20las%20estimula.>
- Burns, P. (2011). *The R Inferno*. Obtenido de [https://www.burns-stat.com/pages/Tutor/R\\_inferno.pdf](https://www.burns-stat.com/pages/Tutor/R_inferno.pdf)
- Cameron, C., & Windmeijer, F. (2012). R-Squared Measures for Count Data Regression Models With Applications to Health-Care Utilization. *Journal of Business & Economic Statistics*, 37-41. doi:<https://doi.org/10.1080/07350015.1996.10524648>
- Caplan, L. R. (2009). *CAPLAN'S STROKE: A CLINICAL APPROACH, FOURTH EDITION*. Saunders Elseiver.
- Cárdenas Gómez, W. (2021). *"Identificación Y Monitoreo De Señales Cerebrales Que Intervienen En Movimientos Involuntarios De Articulaciones en Pacientes Con Parkinson"*. Torreón, Coahuila: Tecnológico Nacional de México Instituto Tecnológico de la Laguna.
- CDC. (17 de Septiembre de 2017). *Prevención de Muertes por Accidente Cerebro Vascula*. Obtenido de CDC: <https://www.cdc.gov/spanish/signosvitales/accidentes-cerebrovasculares/index.html#:~:text=Cada%20a%C3%B1o%2C%20casi%20800%20000,los%20accidentes%20cerebrovasculares%20son%20prevenibles.>
- Chen, Z., Shen, X., Chen, S., & Dai, K. (2017). *Translational Medicine Research in Stroke*. (P. A.Lapchak, & G.-Y. Yang, Edits.) Springer. doi:10.1007/978-981-10-5804-2

- Ciaburro, G., & Venkateswaran, B. (2017). *Neural Networks with R Smart models using CNN, RNN, deep learning, and artificial intelligence principles*. Mapt.
- Constantino, I. (2009). Bleeding in the brain. *Nature America*, 15(10), 1131-1132. doi:<https://doi.org/10.1038/nm1009-1131>
- Copeland, B. (2022). *Inteligencia artificial Enciclopedia Britannica*. Obtenido de <https://www.britannica.com/technology/artificial-intelligence>
- Cramer, S. C. (18 de Enero de 2018). Journal Of Stroke. *Journal Of Stroke*, 57-70. doi:<https://doi.org/10.5853/jos.2017.02796>
- Cramer, S. C., Wolf, S. L., Adams, H. P., Chen, D., Dromerick, A. W., Dunning, K., . . . Broderick, J. P. (Marzo de 2017). Stroke Recovery & Rehabilitation Research: Issues, Opportunities, and the NIH StrokeNet. *Stroke*, 813-819. doi:10.1161/STROKEAHA.116.015501
- Dan, N., & Bao, L. (2014). Emotional state classification from EEG data using machine learning approach. *Neurocomputin*, 129, 94-106. doi:10.1016/j.neucom.2013.06.046
- Delgado, R. (9 de Junio de 2018). *Introducción a los Modelos de Regresión en R*. Obtenido de RPubS by RStudio: <https://rpubs.com/rdelgado/395717>
- Dua, R., Ghotra, S. M., & Pentreath, N. (2017). *Machine Learning with Spark - Second Edition (Root Mean Squared Log Error)*. Obtenido de O'REILLY: <https://www.oreilly.com/library/view/machine-learning-with/9781785889936/4317943c-9452-4013-99b9-d267a2820b23.xhtml>
- Faust, O., Hagiwara, Y., Hong, T. J., Lih, O. S., & Acharya, U. R. (2 de Abril de 2018). Deep learning for healthcare applications based on physiological signals: A review. *Computer Methods and Programs in Biomedicine*, 161, 1-13. doi:10.1016/j.cmpb.2018.04.005
- Francois, C., & Allaire, J. (2017). *Deep Learning whith R* (Vol. 1). MANNING.
- Glen, S. (2019). *RMSE: Root Mean Square Error*. Obtenido de StatisticsHowTo.com: Elementary Statistics for the rest of us: <https://www.statisticshowto.com/probability-and-statistics/regression-analysis/rmse-root-mean-square-error/>
- Han, K., Chapman, S., & Krawczyk, D. (24 de Enero de 2018). Neuroplasticity of cognitive control networks following cognitive training for chronic traumatic brain injury. *NeuroImage: Clinical*, 1-49. doi:10.1016/j.nicl.2018.01.030
- Hermann, D. M., & Chopp, M. (2014). Promoting brain remodelling and plasticity for stroke recovery: therapeutic promise and potential pitfalls of clinical translation. *Lancet Neurol*, 1-23. doi:10.1016/S1474-4422(12)70039-X.
- Hoffman, H. (26 de Abril de 2019). *Neuroplasticidad: estimular su cerebro para mejorar la recuperación de un accidente cerebrovascular*. (Saebo) Obtenido de <https://www.saebo.com/blog/neuroplasticity-stimulating-your-brain-for-stroke-recovery/>
- IBM. (17 de agosto de 2021). *Nodos de árbol de decisión: conceptos básicos*. Obtenido de <https://www.ibm.com/docs/es/spss-modeler/SaaS?topic=options-decision-tree-nodes-basics>
- IBM Cloud Education. (03 de Junio de 2020). *Artificial Intelligence (AI)*. Obtenido de <https://www.ibm.com/cloud/learn/what-is-artificial-intelligence>
- Jaiswal, Sonoo. (2021). *Análisis de regresión en aprendizaje automático*. (Java T Point) Obtenido de Javatpoint: <https://www.javatpoint.com/regression-analysis-in-machine-learning>
- K. Chan, A. (2008). *Biomedical Device Technology Principles and Design*. Springfield: Charles C Thomas.

- Kara, H., Bayir, A., Ak, A., & Degirmenci, S. (2015). Cerebrovascular ischaemia after carbon monoxide intoxication. *Singapore Med J*, 56(2), e26-e28. doi:10.11622/smedj.2015030
- Khan, F., Amatya, B., Galea, M., Gonzenbach, R., & Kesselring, J. (24 de October de 2016). Neurorehabilitation: applied neuroplasticity. *J Neurol*, 1-13. doi:10.1007/s00415-016-8307-9
- Kim, Phil. (2017). *MATLAB DEEP LEARNING: With Machine Learning, Neural Networks and Artificial Intelligence*. Seoul, Korea: Apress. doi:DOI 10.1007/978-1-4842-2845-6
- Kumar Chinnamgari, S. (2019). *R Machine Learning Projects*. Mapt.
- Lazaridis, C., & Smielewski, P. (2013). Optimal cerebral perfusion pressure: are we ready for it? *Neurological Research*, 35(2), 138-149.
- Liu, L., Liu, N., Zhang, Y., Li, Y., Rui, X., & Yang, Z. (2020). Machine learning approaches for estimating building energy consumption. *IOP Conf. Series*, 474, 1-6. doi:10.1088/1755-1315/474/5/052072
- López, P. (29 de 06 de 2020). ¿ *Qué es un archivo CSV y para qué sirve?* Obtenido de geeknetic: <https://www.geeknetic.es/Archivo-CSV/que-es-y-para-que-sirve>
- Lotte, F. (2014). A Tutorial on EEG Signal-processing Techniques form Mental-state Recognition in Brain-Computer interfaces. En *Guide to Brain-Computer Music Interfacing*. London: Springer. doi:10.1007/978-1-4471-6584-2\_7
- Marsland, S. (2015). *Machine Learning An Algorithmic Perspective*. Taylor & Francis Group.
- MAYO CLINIC. (Septiembre de 2019). *Accidente Cerebrovascular*. Obtenido de [mayoclinic.org/es-es/diseases-conditions/stroke/symptoms-causes/syc-20350113](https://www.mayoclinic.org/es-es/diseases-conditions/stroke/symptoms-causes/syc-20350113)
- Nidal, K., & Malik, A. (2015). *ECG/ERP ANALYSIS METHODS AND APPLICATIONS*. Broken Sound Parkway : Taylor & Francis Group.
- Noticias Parlamento Europeo. (09 de Agosto de 2020). ¿ *Qupé es la inteligencia artificial y cómo se usa?* Obtenido de <https://www.europarl.europa.eu/news/es/headlines/society/20200827STO85804/que-es-la-inteligencia-artificial-y-como-se-usa>
- Noticias Parlamento Europeo. (09 de Agosto de 2020). ¿ *Qupé es la inteligencia artificial y cómo se usa?* Obtenido de <https://www.europarl.europa.eu/news/es/headlines/society/20200827STO85804/que-es-la-inteligencia-artificial-y-como-se-usa>
- NURORHB; Vinalopó, Vithas ;. (14 de Diciembre de 2017). *Lóbulos frontales: funciones cognitivas*. Obtenido de <https://neurorhb.com/blog-dano-cerebral/lobulos-frontales-funciones-cognitivas/>
- OMS. (09 de Diciembre de 2020). *La OMS revela las principales causas de muerte y discapacidad en el mundo: 2000-2019*. Obtenido de <https://www.who.int/es/news/item/09-12-2020-who-reveals-leading-causes-of-death-and-disability-worldwide-2000-2019>
- OPS. (2021). *La carga de las enfermedades cardiovasculares en la Región de las Américas, 2000-2019*. Obtenido de Portal de Datos de NMH. Organización Panamericana de la Salud: <https://www.paho.org/es/enfermedades-no-transmisibles-salud-mental/portal-datos-enfermedades-no-transmisibles-salud-0>
- Organización Mundial de la Salud. (9 de diciembre de 2020). *Las 10 principales causas de defunción*. Obtenido de Organización Mundial de la Salud: <https://www.who.int/es/news-room/fact-sheets/detail/the-top-10-causes-of-death>

- Osuna Suárez, E., Caro Henao, L., & P. G. (2016). *NEUROANATOMÍA Fundamentos de neuroanatomía estructural, funcional y clínica*. Centro Editorial Universidad Nacional de Colombia.
- Past & Future of Stroke Care in Europe. (10 de Enero de 2017). *The CNS Journal*, 2(2), 19-23.
- Pérez R, Germán Enrique. (2007). *Enfermedad cerebrovascular* (Vol. Guia Neurológica 8). Colombia.
- Piquero, Iván. (26 de 03 de 2021). *Diferencia entre sustancia gris y blanca del cerebro*. (Psicología-Online ) Obtenido de <https://www.psicologia-online.com/diferencia-entre-sustancia-gris-y-blanca-del-cerebro-5603.html>
- Ponce Cruz, P. (2010). *Inteligencia Artificial Con Aplicaciones A La Ingenieria*. Alfaomega.
- Pons, J., Raya, R., & González, J. (2016). *Emerging Therapies in Neurorehabilitation II* (Vol. 10). Madrid: Springer. doi:10.1007/978-3-319-24901-8
- Rouhiainen, L. (2018). *Inteligencia Artificial 101 cosas que debes saber hoy sobre nuestro futuro*. Alienta Editorial.
- Rouse, M. (Abril de 2021). *ComputerWeekly.es*. (Inteligencia Artificial o IA) Obtenido de <https://www.computerweekly.com/es/definicion/Inteligencia-artificial-o-IA>
- Sammut, C., & Webb, G. (2010). *Encyclopedia of Machine Learning*. Springer. doi:<https://doi.org/10.1007/978-0-387-30164-8>
- Sasmita, Andrew Octavian; Kuruvilla, Joshua ; Kiong Ling, Pick. (18 de Abril de 2018). *Harnessing Neuroplasticity: Modern Approaches and Clinical Future*. (T. & Francis, Ed.) *International Journal of Neuroscience*, 1-41. doi:10.1080/00207454.2018.1466781
- Sieger, F. A. (2016). *Boletín cardiecol fase II N° 5*. Obtenido de <http://www.cardiecol.org/comunidad/bolet%3%ADn-cardiecol-5-especial-sobre-acv>
- Snell, Richard S ; Sunyer, Claustre Pont;. (2014). *Neuroanatomia Clínica*. Barcelona: Wolters Kluwer : Lippincott Williams & Wilkins.
- Sullivan, W. (2017). *Machine Learning Beginners Guide Algorithms: Supervised & Unsupervised Learning, Decision Tree & Random Forest Introduction*. Healthy Pragmatic Solutions Inc. .
- Theobald, C. (1974). Generalizations of Mean Square Error Applied to Ridge Regression. *journal of the Royal Statistical Society: Series B (Methodological)*, 36(1), 103-106. doi:<https://doi.org/10.1111/j.2517-6161.1974.tb00990.x>
- Tortora, G., & Derrickson, B. (s.f.). *Principios de Anatomía y fisiología* (Vol. 11). Panamericana.
- Vapnik, V., Golowich, S., & Smola, A. (1996). Support Vector Method for Function Approximation, Regression Estimation, and Signal Processing. 281-287.
- Vidatecno.net. (2016). *El concepto detrás de las interfaces cerebro computadora*. (Vidatecno.net) Obtenido de <https://vidatecno.net/el-concepto-detras-de-las-interfases-cerebro-computadora/>
- Waxman, Stephen G. (2018). *Neuroanatomía Clínica* (26 ed.). Mc Graw Hill Lange.
- WEN, T., & ZHANG, Z. (28 de Abril de 2018). Deep Convolution Neural Network and Autoencoders-Based Unsupervised Feature Learning of EEG Signals. *IEEE ACCESS*, 6, 25399- 25410. doi:10.1109/ACCESS.2018.2833746
- Wenderoth, N. (03 de Abril de 2018). Motor Learning Triggers Neuroplastic Processes While Awake and During Sleep. *American College of sports Medicine*, 1-32. doi:10.1249/JES.0000000000000154
- World Health Organization. (2019). *Stroke, Cerebrovascular accident*. Recuperado el 2021, de World Health Organization: <http://www.emro.who.int/health-topics/stroke->

cerebrovascular-

accident/index.html#:~:text=Annually%2C%2015%20million%20people%20worldwide, cause%20is%20high%20blood%20pressure.

Yoav, M., & Roint, B. (27 de febrero de 2019). Introduction to artificial intelligence in medicine. *Minimally Invasive Therapy & Allied Technologies*, 28, 73-81.

Zhang, R., Zhang, Z., & Chopp, M. (2016). Function of neural stem cells in ischemic brain repair processes. *Journal of Cerebral Blood Flow &*, 1-10. doi:10.1177/0271678X16674487