



Clasificación de la intención de movimiento de la mano mediante señales electroencefalográficas: una aproximación basada en técnicas de aprendizaje automático

Classification of hand movement intention using electroencephalographic signals: a machine learning-based approach

David Augusto Rodríguez Chamorro*

Daniel Felipe Gómez Muñoz**

Valentina Ramírez Rodríguez***

* Estudiante de Ingeniería en sistemas, Noveno semestre. Fundación Universitaria Católica Lumen Gentium. Email: david.rodriguez01@unicatolica.edu.co, Orcid: <https://orcid.org/0000-0002-4287-5089>

** Estudiante de Ingeniería en sistemas. Noveno semestre. Fundación Universitaria Católica Lumen Gentium. Email: daniel.gomez02@unicatolica.edu.co, Orcid: <https://orcid.org/0009-0009-8539-0709>

*** Estudiante de Ingeniería en sistemas. Noveno semestre. Fundación Universitaria Católica Lumen Gentium. Email: valentina.ramirez01@unicatolica.edu.co, Orcid: <https://orcid.org/0009-0007-9357-1791>

Resumen:

A nivel mundial, más de 40 millones de personas han perdido al menos un miembro superior debido a diversas causas. En 2020, en Colombia se registraron 170 casos de víctimas de explosiones que sufrieron amputaciones de extremidades superiores. La pérdida de un miembro superior genera limitaciones que afectan la calidad de vida. Como mecanismo para contribuir con la calidad de vida de quienes sufren esa limitación se han desarrollado interfaces cerebro-computadora que permiten el control de las prótesis mediante señales cerebrales. En resumen, las prótesis mecánicas y las interfaces cerebro-computadora son avances prometedores. Este documento analiza los avances en este campo y presenta los hallazgos y resultados obtenidos.

Palabras Clave: Interacción humano-máquina, Aprendizaje de máquina, Intención de movimiento, Procesamiento Digital de Señales, Electroencefalografía (EEG).

Abstract:

Worldwide, more than 40 million people have lost at least one upper limb due to various causes. In 2020, 170 cases of explosion victims who suffered upper limb amputations were recorded in Colombia. The loss of an upper limb generates limitations that affect the quality of life. As a mechanism to contribute to the quality of life of those who suffer from this limitation, brain-computer interfaces have been developed that allow the control of prostheses through brain signals. In summary, mechanical prosthetics and brain-computer interfaces are promising developments. This document analyzes the advances in this field and presents the findings and results obtained.

Keywords: Human-machine interaction, Machine learning, Movement intention, Digital Signal Processing (DSP), Electroencephalography (EEG).

Fecha de recepción: 17 de enero de 2023

Fecha de aprobación: 4 de abril de 2023

Semillas del Saber Vol. 3 - No. 1
e-ISSN 2805-7511 • pp. 106-117

Introducción

Según la Organización Mundial de la Salud, a nivel mundial cerca de 40 millones de personas han sufrido la pérdida de al menos uno de sus miembros superiores. Muchas de estas ausencias se deben a accidentes que causaron lesiones traumáticas, conflictos armados, enfermedades como la diabetes y el cáncer, malformaciones genéticas, enfermedades vasculares e infecciones como la gangrena (OMS, 2021). En Colombia no hay estadísticas precisas, sin embargo, según la Acción Integral Contra Minas Antipersonal – AICMA, en el año 2020 se registraron 170 casos de personas que fueron víctimas de explosiones con minas u otros dispositivos explosivos. No todas estas víctimas perdieron un miembro superior, pero algunos sí. Es importante señalar que también hay personas que perdieron sus miembros superiores debido a accidentes u otras causas (Acción Integral Contra Minas Antipersonal – AICMA, 2020).

Las personas que han experimentado la pérdida de alguno de sus miembros superiores, enfrentan distintos retos y limitaciones en su vida diaria. Incluso tareas cotidianas o de rutina, como vestirse, bañarse, cocinar u otras actividades del hogar, pueden resultar complicadas sin la ayuda adecuada. Además, la falta de un miembro puede afectar la estabilidad y equilibrio del individuo, lo que puede generar problemas en su movilidad. A menudo, también enfrentan dificultades emocionales y otros desafíos que deben superar para adaptarse a su nueva realidad. Las prótesis mecánicas han surgido como una tecnología que utiliza señales emitidas por el cerebro, también conocidas como señales electroencefalográficas (EEG), lo que permite a las personas controlar las prótesis mediante la actividad cerebral (Bedoya et al., 2013).

En la actualidad, se han logrado varios avances para mejorar la calidad de vida de las personas que sufren la pérdida de sus miembros, uno de estos

son las prótesis mecánicas. Estas ayudan a mejorar gran parte de su movilidad, su participación social e incluso su salud mental. El objetivo de las prótesis es brindar ayuda para la realización de distintas actividades, sin embargo, estas nunca llegan a reemplazar el miembro faltante (Brito et al., 2013).

Se ha desarrollado una interfaz cerebro-computadora que permite la clasificación entre la imaginación del movimiento y la intención motora a partir de las señales electroencefalográficas (EEG), mediante el procesamiento digital de señales para su clasificación. Se llevaron a cabo una serie de pruebas para el algoritmo implementado utilizando conjuntos de datos de uso libre encontrados en internet con fines investigativos, logrando determinar el alcance y las limitaciones de dicha interfaz. De esta manera, se podría mejorar la calidad de vida de las personas que han sufrido la pérdida de un miembro superior.

Marco teórico o conceptual

La pérdida parcial o total de movilidad en las extremidades puede generar deficiencias estructurales o funcionales de los miembros superiores e inferiores, limitaciones en la ejecución de actividades diarias y restricciones en la interacción social (Henao-Lema Perez-Parra, 2010). Por lo tanto, la rehabilitación de personas con limitaciones motoras es un proceso crucial que puede mejorar significativamente su calidad de vida.

En este sentido, el uso de dispositivos de asistencia tecnológica, como los comandados mediante interfaces cerebro-computador (BCI), puede mejorar los procesos de rehabilitación y potenciar la neuroplasticidad (Sharma et al., 2013) (Liu et al., 2012). Además, se ha demostrado que el uso de dispositivos de asistencia real en lugar de virtuales puede mejorar el sistema locomotor del miembro superior (Van Dokkum et al., 2015).

En la actualidad, el monitoreo de la actividad cerebral, específicamente de las señales electroencefalográficas (EEG), es una herramienta útil para el diagnóstico y tratamiento de diversas condiciones médicas (Torres et al., 2014). Las señales

electroencefalográficas (EEG) son de gran importancia para analizar la actividad cognitiva de una persona, y gracias a los avances en inteligencia artificial, se han convertido en una parte fundamental de los procesos de extracción de patrones, clasificación y aprendizaje de señales EEG (Montes et al., 2017).

Figura 1.

Procesamiento digital de señales



Fuente: propia

El aprendizaje automático es una rama de la inteligencia artificial que permite que las máquinas aprendan de los datos y encuentren patrones por sí mismas. Se utiliza en diversos campos y ofrece un gran potencial para la innovación tecnológica.

En particular, la clasificación de la intención de movimiento de la mano mediante señales EEG es un tema de investigación relevante, ya que puede mejorar la precisión y eficacia de los dispositivos de asistencia tecnológica para personas con limitaciones motoras en las extremidades superiores. Para ello, se han desarrollado diversas técnicas de aprendizaje automático, se usaron FFS, GR, que permiten extraer patrones relevantes de las señales EEG y clasificar la intención de movimiento de la mano con alta precisión (Hakonen et al., 2015)

El procesamiento de señales digitales se divide en cuatro bloques: conjuntos de datos, preprocesamiento, entrenamiento y validación. En la fase de datos, se realiza una revisión bibliográfica para identificar los conjuntos de datos más importantes y las técnicas de aprendizaje automático utilizadas en la clasificación de señales electroencefalográficas (EEG) relacionadas con la intención de movimiento de las extremidades superiores. En el bloque de preprocesamiento, se ejecutan datos seleccionados y algoritmos de aprendizaje automático. Luego, en la fase de entrenamiento, se realiza un

ejercicio utilizando los datos previamente procesados. Finalmente, el análisis define el alcance y los límites del algoritmo de aprendizaje automático a través de pruebas contra un protocolo establecido.

Para la clasificación de las señales electroencefalográficas EEG se aplicó un filtro paso-banda Butterworth de orden cuatro. Este tipo de filtro digital se utiliza comúnmente en el procesamiento de señales para eliminar o atenuar ciertas frecuencias no deseadas, con una frecuencia de muestreo de $f_s=512\text{Hz}$ y con una banda de frecuencia entre 1Hz y 20Hz.

Revisión Literaria

Durante una revisión bibliográfica realizada en diversas plataformas de búsqueda como Researchgate, IEEE Explore, Google Scholar, Springerlink y Dialnet, se encontraron diversos precedentes nacionales e internacionales en cuanto a la clasificación y tipo de señal del electroencefalograma (EEG) para detectar el movimiento intencional de las extremidades superiores.

Entre los precedentes internacionales encontrados, se destacó un estudio realizado en el Instituto Nacional de Tecnología de Calicut, India, que tuvo como objetivo analizar los efectos de diferentes


señales electroencefalográficas EEG y métodos de procesamiento, utilizando diferentes señales para extraer información oculta de ellas (Subha et al., 2010). Además, en la Universidad de Zaragoza, España, se realizó un estudio sobre la decodificación continua de la intención de movimiento de los movimientos analíticos autoiniciados de las extremidades superiores a partir del EEG pre-movimiento. Además, en la Universidad de Corea, Seúl, Corea, se llevó a cabo un estudio sobre la clasificación de los movimientos de la mano en señales electroencefalográficas EEG para el control manual de un robot no invasivo basado en BCI.

Con respecto al contexto nacional, se encontró un estudio realizado por estudiantes de la Universidad del Valle que evaluó la contribución de la covarianza de las señales electroencefalográficas EEG a la interfaz cerebro-computadora de la visualización mente motora en pacientes con lesión medular (Ferrin et al., 2019). También se encontró un trabajo de la Universidad del Norte, Colombia, en el que se describen algoritmos de clasificación de señales electroencefalográficas EEG con aplicaciones para interfaz cerebro-computadora (BCI) (Delgado, 2011).

En cuanto al estudio de (López et al., 2014), se describió la decodificación continua de la intención de movimiento de los movimientos analíticos espontáneos de las extremidades superiores a partir del EEG previo al movimiento. Este estudio se centró en la construcción de un decodificador de movimiento que analiza las extremidades superiores utilizando la interfaz cerebro-máquina (BMI) y señales electroencefalográficas EEG previas al movimiento. Los autores realizaron siete ejercicios de detección de intención motora en diferentes participantes para analizar el rendimiento de los métodos de decodificación de movimiento de las extremidades superiores. Este estudio se llevó a cabo en la Universidad de Zaragoza en España.

Figura 2.

Movimientos analíticos de miembros superiores



Fuente: Tomado de (López-Larraz et al., 2014)

En el estudio de Cho et al., (2019), se describió cómo se puede utilizar la clasificación de los movimientos de la mano en las señales de EEG para el control manual de un robot no invasivo basado en BCI. Los autores analizaron la decodificación de cinco representaciones visuales manuales diferentes de señales EEG para el control manual de robots desde sistemas de interfaz cerebro-computadora (BCI) basados en la clasificación de señales EEG en la dirección del movimiento espontáneo. Se utilizaron intervalos de tiempo específicos y métodos de modelado espacial común (CSP) para clasificar cinco movimientos diferentes de la mano fuera de línea y se logró una precisión de clasificación del 56,83 % para ejecución motora (ME) y del 51,01 % para imagen motora (MI). Este estudio se realizó en la Universidad de Corea en Seúl, Corea del Sur.

Además de los estudios mencionados anteriormente, se identificaron otros trabajos relevantes en el campo de la clasificación y tipo de señal del electroencefalograma (EEG) para detectar el movimiento intencional de las extremidades superiores.

En un estudio llevado a cabo en la Universidad de California, Estados Unidos, se exploró la utilización de técnicas de aprendizaje automático para clasificar y reconocer los movimientos de las extremidades superiores a partir de señales EEG. Los

investigadores desarrollaron un algoritmo basado en redes neuronales convolucionales que logró una alta precisión en la detección de los movimientos intencionales.

En el Instituto de Neurociencias de la Universidad de Granada, España, se realizó una investigación para analizar la variabilidad de las señales electroencefalográficas EEG durante los movimientos de las extremidades superiores. Se utilizaron métodos de procesamiento de señales y técnicas de análisis de variabilidad para identificar patrones característicos relacionados con el movimiento intencional.

En la Universidad de Sydney, Australia, se llevó a cabo un estudio que exploró el uso de señales electroencefalográficas EEG para controlar prótesis de extremidades superiores. Los investigadores desarrollaron un sistema de interfaz cerebro-computadora que permitía a los usuarios controlar una prótesis utilizando sus intenciones de movimiento registradas a través de las señales electroencefalográficas EEG.

En conclusión, la revisión bibliográfica reveló una serie de estudios nacionales e internacionales que han abordado la clasificación y tipo de señal electroencefalográfica (EEG) para detectar el movimiento intencional de las extremidades superiores. Estos trabajos han utilizado diversas técnicas de procesamiento de señales y análisis de datos para mejorar la precisión y confiabilidad de los sistemas de detección y control basados en señales electroencefalográficas (EEG).

Metodología

En este proyecto de investigación se llevó a cabo un estudio descriptivo con el objetivo de examinar el propósito de caminar y caminar utilizando señales electroencefalográficas (EEG). El método utilizado se basó en un enfoque inductivo con componentes cualitativos, exploratorios, descriptivos y experimentales. Se comenzó con un estudio exhaustivo de la literatura para identificar prácticas similares o relacionadas.

Se emplearon herramientas de investigación como Google Scholar, IEEE Xplore, Researchgate y otras para recopilar datos de documentos relevantes disponibles públicamente. Para el análisis de los datos, se utilizó el software libre con licencia GNU *Google Collaboratory* y el lenguaje de programación *Python*. Se utilizaron las librerías de *SCIKIT LEARN* para el aprendizaje automático. Los resultados del análisis corresponden a la Universidad Unicatólica.

En cuanto a la selección de datos, se utilizaron datos disponibles públicamente que contenían señales electroencefalográficas (EEG) de personas en estado de atención y reposo. Estos datos fueron seleccionados debido a la importancia de los estados de atención y relajación en el estudio de los procesos cognitivos, y la clasificación de estos estados de conciencia se considera un problema relevante en el análisis de las señales electroencefalográficas (EEG).

El preprocesamiento de los datos se realizó utilizando una combinación de filtrado espacial de tipo CSP y filtrado de paso de banda, aplicados en secuencia a través de una canalización. El filtrado de paso de banda se utilizó para extraer las bandas de frecuencia pertinentes para el enfoque y la relajación, mientras que el filtrado de tipo CSP se empleó para extraer la región correspondiente.

Figura 3.
Fases del proyecto



Fuente: Propia

La metodología implementada en este estudio consistió en la aplicación de cuatro clasificadores: Análisis Discriminante Lineal (*LDA*), Máquina de Soporte Vectorial Lineal (*SVM-Linear*), Red Neuronal de Perceptrón Multicapa (*MLP*) y Árboles de Bosques Aleatorios (*Random Forest*), con el objetivo de evaluar su rendimiento en la clasificación de señales electroencefalográficas (EEG) en dos estados mentales diferentes.

En cuanto a la implementación, se seleccionaron cuatro métodos de aprendizaje automático diferentes: Análisis Discriminante Lineal (*LDA*), Máquina de Soporte Vectorial Lineal (*SVM-Linear*), Red Neuronal de Perceptrón Multicapa (*MLP*) y Árboles de Bosques Aleatorios (*Random Forest*). Estos algoritmos fueron elegidos debido a su amplio uso en el campo de las señales electroencefalográficas (EEG) y a los buenos resultados obtenidos en investigaciones previas.

Se utilizó un conjunto de datos de señales electroencefalográficas (EEG) que incluía registros de individuos en dos estados mentales diferentes: reposo y actividad mental. Se aplicó la técnica de validación cruzada en un grupo de tres para evaluar el rendimiento de los clasificadores de forma individual para cada individuo. El conjunto de datos

se dividió en una proporción del 80% para entrenamiento y el 20% restante para validación, con el fin de evaluar la eficacia de los clasificadores en la etapa de entrenamiento y en general.

En la primera etapa del análisis, se evaluó la efectividad de los clasificadores utilizados de forma individual. Los resultados obtenidos indicaron que los clasificadores *SVM* y *RandomForest* demostraron el mejor rendimiento. En la segunda parte del experimento, se realizaron las mismas tres pruebas con todos los sujetos agrupados. Los resultados obtenidos difirieron de los obtenidos en la primera parte del experimento.

Durante el entrenamiento, los clasificadores que mostraron el mejor rendimiento fueron *RandomForest* y *MLP*, mientras que durante las pruebas o mejoras, los mejores clasificadores fueron *MLP* y *RandomForest*. En general, los resultados obtenidos fueron consistentes y no mostraron una desviación superior al 1,5% en los resultados de validación.

Se utilizaron varias métricas para evaluar el rendimiento de los clasificadores, incluyendo precisión, coeficiente de correlación de Matthews (MCC) y área bajo la curva ROC (AUC-ROC). Estas estadísticas se utilizaron para comparar el desempeño de los clasificadores y determinar cuál presentó el mejor

rendimiento. El método utilizado en este estudio permitió analizar la actividad de diferentes partes para clasificar las señales EEG correspondientes a dos estados mentales diferentes.

En conclusión, los resultados obtenidos indican que los clasificadores *SVM*, *MLP* y *RandomForest* presentan un buen desempeño en la clasificación de señales electroencefalográficas (EEG) y pueden ser utilizados para desarrollar métodos de clasificación de señales electroencefalográficas (EEG) que permitan detectar diferentes estados mentales.

Este proyecto permitió la implementación y evaluación de diferentes métodos de aprendizaje automático para la clasificación de señales EEG en los estados mentales de atención y relajación. Los resultados obtenidos demostraron que los

clasificadores *SVM* y *Random Forest* presentaron el mejor rendimiento al analizar los datos de forma individual para cada individuo, mientras que los clasificadores *RandomForest* y *MLP* obtuvieron el mejor rendimiento en el conjunto de datos de entrenamiento.

Hallazgos y Resultados

En primer lugar, se realizaron cuatro clasificaciones: el Análisis Discriminante Lineal (*LDA*), la Máquina de Vectores de Soporte Lineal (*SVM-Linear*), la Red Neuronal de Perceptrón Multicapa (*MLP*) y el Árbol Forestal Aleatorio. Posteriormente, se desarrolló un protocolo experimental para validar el rendimiento de estas arquitecturas en relación al conjunto de datos seleccionado.

Tabla 1.

Artículos con las técnicas aplicadas


ARTÍCULO	AÑO	PACIENTES	GESTOS	TÉCNICAS
Artículo 1	2013	No Especifica	3	SVM, LDA
Artículo 2	2011	No Especifica	4	BURG, YULLER-WALKER
Artículo 3	2013	60	140	TW, FRS
Artículo 4	2017	9	4	DWT, MODWT, DB2, DB4
Artículo 5	2021	14	2	FFS, GR

Fuente: Los autores

Las pruebas se dividieron en dos series: la primera evaluó el rendimiento de forma independiente para cada uno de los cuarenta individuos, mientras que la segunda evaluó el rendimiento general al agrupar a todos los individuos en un solo conjunto de datos.

Figura 4.

Validación cruzada para cada individuo




Fuente: Propia

Para evaluar el desempeño de los cuatro clasificadores aplicados de forma independiente a cada individuo, se utilizó la técnica de validación cruzada en un grupo de tres clasificadores. Los resultados indican que se logra el mejor rendimiento al utilizar los clasificadores *SVM* y *RandomForest*. A

continuación, se llevó a cabo una segmentación del conjunto de datos, asignando el 80% de los datos para entrenamiento y el 20% para validación. Los resultados obtenidos en el entrenamiento y validación se analizaron con el objetivo de validar las hipótesis planteadas en el estudio.

Figura 5.


Entrenamiento para cada individuo (80% datos)



Fuente: Propia

Figura 6.


Entrenamiento agrupando todos los datos de los individuos (80% datos)



Fuente: Propia

Figura 7.


Validación o generalización para cada individuo (20% datos)



Fuente: Propia

Figura 8.

Validación o generalización agrupando todos los datos de los individuos (20% datos)




Fuente: propia

Se encontró que los clasificadores *SVM* y *RandomForest* exhiben un mejor rendimiento en cuanto a precisión y tasa de éxito en la validación del conjunto de datos en comparación con los otros

dos clasificadores (*LDA* y *MLP*). Estos resultados sugieren que los clasificadores *SVM* y *RandomForest* son los más idóneos para la clasificación de los datos utilizados en el estudio.

Figura 9.

Pruebas de validación cruzada con los datos agrupados



Fuente: Propia

En resumen, los hallazgos y resultados obtenidos en el estudio sugieren que tanto los clasificadores *SVM* como *RandomForest* son más efectivos para clasificar datos del conjunto de datos utilizado en el estudio. Estos resultados son consistentes con las hipótesis propuestas y demuestran la efectividad de las arquitecturas propuestas en la clasificación de datos. Estos resultados pueden ser útiles para desarrollar soluciones de clasificación de datos en otros contextos y aplicaciones.

Conclusiones:

La conclusión del artículo es que se realizó una revisión completa de la literatura para seleccionar un conjunto de datos de imágenes de motor para las extremidades superiores y un algoritmo de aprendizaje automático para clasificar las señales electroencefalográficas (EEG). Después de ejecutar el algoritmo con 14 datos para realizar las pruebas, se logró el objetivo de probar la capacidad de aprendizaje del algoritmo con los parámetros utilizados.

Además, se ha destacado que los clasificadores utilizados para interpretar estas señales electroencefalográficas (EEG) varían según la técnica utilizada y también varía el rendimiento de cada dato utilizado. Se destacó el rendimiento consistente y superior de *MLP* sobre otros clasificadores usados. En general, se puede concluir que los resultados obtenidos son muy prometedores para la clasificación de señales electroencefalográficas (EEG) y que *MLP* es una técnica de clasificación efectiva para este tipo de datos.

Después de obtener los resultados, se puede concluir que la clasificación de las señales electroencefalográficas (EEG) para la imaginación motora de las extremidades superiores es factible y que el algoritmo de aprendizaje automático se utiliza de manera efectiva para dicha tarea. Además, se encontró que el clasificador *MLP* fue el que mejor desempeño obtuvo en comparación con otros clasificadores utilizados.

Estos resultados son importantes porque la clasificación de señales electroencefalográficas (EEG)

para imágenes motoras tiene diversas aplicaciones en el campo de la rehabilitación y control de prótesis, que pueden mejorar la calidad de vida de las personas con discapacidades de movilidad. Además, la selección del algoritmo de aprendizaje automático correcto y una técnica de clasificación eficiente pueden mejorar la precisión y la confiabilidad del clasificador, lo cual es importante para la implementación en aplicaciones clínicas y de recuperación funcional.

En resumen, la revisión de la literatura, la selección de conjuntos de datos y algoritmos, así como las pruebas realizadas en este estudio, nos permiten concluir que la clasificación de las señales electroencefalográficas (EEG) para la imaginación motora del miembro superior es posible y la técnica de clasificación *MLP* es posible, más eficaz para este trabajo. Estos resultados son importantes para el desarrollo de soluciones protésicas de rehabilitación y control, y pueden guiar futuras investigaciones en esta área.

Referencias

- Acción Integral Contra Minas Antipersonal – AICMA. (2020). *Informe de gestión campaña colombiana contra minas*. https://colombiasinminas.org/wp-content/uploads/2021/08/INFORME_GESTION_2020-1-check-1.pdf
- Bedoya, A., Giraldo, J., Pardo, I.-D., y Becerra, M. (2013). *Interfaz cerebro computador basado en señales EEG para el control de movimiento de una prótesis de mano usando ANFIS*. - Dialnet. <https://dialnet.unirioja.es/servlet/articulo?codigo=4776223>
- Brito, J., Quinde, M., Cusco, D., y Calle, J. (2013). Estudio del estado del arte de las prótesis de mano. *Revista Ingenius*, 9, 57-64. <https://www.redalyc.org/articulo.oa?id=505554814008>
- Cho, J., Jeong, J., Shim, K., Kim, D., y Lee, S. W. (2019). Classification of Hand Motions within EEG Signals for Non-Invasive BCI-Based Robot Hand Control. *Proceedings - 2018 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2018*, 515–518. <https://doi.org/10.1109/SMC.2018.00097>
- Delgado, J. (2011). Clasificación de Señales Cerebrales Durante la Ejecución de Actividad Motora Imaginaria. [Documento Word].
- Ferrin, C., Loaiza, H., Pierre, J., y Vélez, P. (2019). Evaluación del aporte de la covarianza de las señales electroencefalográficas a las interfaces cerebro-computador de imaginación motora para pacientes con lesiones de médula espinal. *Tecnológicas*, 22(46), 213–231. <https://doi.org/10.22430/22565337.1392>
- Hakonen, M., Piitulainen, H., and Visala, H. (2015). Current state of digital signal processing in myoelectric interfaces and related applications. *Biomed. Signal Process. Control*, 18, 334–359
- Henao-Lema Perez-Parra. (2010). *Lesiones medulares y discapacidad: revisión bibliográfica*. http://www.scielo.org.co/scielo.php?pid=S1657-59972010000200006&script=sci_abstract&tlng=es
- Liu, J., Yang, X., Jiang, L., Wang, C., & Yang, M. (2012). Neural plasticity after spinal cord injury. *Neural Regeneration Research*, 7(5), 386. <https://doi.org/10.3969/J.ISSN.1673-5374.2012.05.010>
- López, E., Montesano, L., Gil, Á. y Minguez, J. (2014). Continuous decoding of movement intention of upper limb self-initiated analytic movements from pre-movement EEG correlates. *Journal of NeuroEngineering and Rehabilitation*, 11(1), 1–15. <https://doi.org/10.1186/1743-0003-11-153/TABLES/5>

- Montes, L., Isaza, G., & Castillo, L. F. (2017). *Präna: Una aplicación de la Inteligencia Computacional para el procesamiento de datos EEG en la clasificación de un estado mental*. *comparative genomics of methano-massiliococcus luminyensis of diverging buffaloes for methane emissions View project Application of Convolutional Neural Networks for Steganalysis View project*. <https://www.researchgate.net/publication/320700987>
- OMS. (2021). *Discapacidad y salud*. <https://www.who.int/es/news-room/fact-sheets/detail/disability-and-health>
- Subha, D., Joseph, P., Acharya U, y Lim, C.. (2010). EEG signal analysis: a survey. *Journal of Medical Systems*, 34(2), 195–212. <https://doi.org/10.1007/s10916-008-9231-z>
- Sharma, N., Classen, J., y Cohen, L. G. (2013). Neural plasticity and its contribution to functional recovery. *Handbook of Clinical Neurology*, 110, 3–12. <https://doi.org/10.1016/B978-0-444-52901-5.00001-0>
- Torres, F., Sánchez, C., & Palacio-Baus, K. (2014). *Adquisición y análisis de señales cerebrales utilizando el dispositivo MindWave | Maskana*. <https://publicaciones.ucuenca.edu.ec/ojs/index.php/maskana/article/view/540>
- Van Dokkum, L. E. H., Ward, T., & Laffont, I. (2015). Brain computer interfaces for neurorehabilitation – its current status as a rehabilitation strategy post-stroke. *Annals of Physical and Rehabilitation Medicine*, 58(1), 3–8. <https://doi.org/10.1016/J.REHAB.2014.09.016>