

1. Introducción

El dolor es una sensación desagradable y difícil de describir, dicha sensación se puede ver afectada por aspectos psicológicos, fisiológicos, culturales, emocionales, entre otros (Ilana, 1979). La correcta evaluación del mismo, permite la detección y manejo de sus causas (Tatum, 2021). Actualmente, el dolor es evaluado de acuerdo al reporte dado por el paciente por medio de escalas tales como Escalas Análogas Visuales (VAS) (Manworren y Stinson, 2016). y Escalas de Calificación Numérica (NRS) (Bai y Zhang, 2016) principalmente. Adicionalmente, se realiza una evaluación médica que ayuda a establecer diferentes parámetros como: tipo de dolor, intensidad del dolor, área del dolor, entre otros (Manworren y Stinson, 2016). Existen situaciones en las que los pacientes no tienen la posibilidad de reportar su nivel de dolor, por ejemplo bebés o pacientes con algún tipo de dificultad para comunicarse, en estos casos el tratamiento de dolor se convierte en un proceso más difícil y el no tratamiento del mismo, en cualquier tipo de paciente, puede llegar a generar estados de depresión, dificultades relacionales, disminución en la calidad de vida, y discapacidades por dolor crónico (Yu y Sun, 2020). El sistema nervioso central cuenta con un tipo de células especializadas en el envío de información de estímulos y acciones de respuesta llamadas neuronas. Dichas neuronas cumplen la tarea de transportar información a través de potenciales de acción, estos potenciales de acción son evidenciados como impulsos eléctricos o diferencias de potenciales eléctricos que viajan desde y hacia el cerebro (Grabowski y Tortora, 2000). Los potenciales de acción que se llevan a cabo en los distintos lóbulos cerebrales forman conjuntos de patrones de señales eléctricas denominadas ondas cerebrales (Tortora y Nielsen, 1995). Estas ondas contienen información de cada estímulo externo o interno que experimenta el cuerpo humano en un lapso de tiempo. Las ondas se suelen clasificar en rangos de frecuencia y son una herramienta útil para detectar patologías como la epilepsia o el Alzheimer (Tatum, 2021). Algunos autores han observado que a través del análisis de las ondas cerebrales Alfa (α) y Beta (β) se pueden obtener características relacionadas con el nivel de dolor que experimenta una persona (Yu y Sun, 2020). De esta manera, el objetivo de este trabajo es a partir de este principio, analizar las diferentes ondas cerebrales mediante algoritmos de inteligencia computacional con el fin de evaluar presencia y ausencia de dolor en una persona que recibe un estímulo externo.

Las ondas de electroencefalografía (EEG) permiten medir la actividad cerebral (Grabowski y Tortora, 2000). Algunos autores han evaluado estas señales para cuantificar el dolor. En (Bonotis y otros, 2019) los autores utilizan árboles de decisión estocásticos que clasifican el nivel de dolor de acuerdo a la desviación del nivel de energía de las ondas cerebrales δ , θ , α , β , y γ , logrando identificar 5 niveles diferentes de dolor en un experimento con estímulos en frío (Cold Pressor Test). Alazrai y otros (Alazrai y otros, 2019) logran clasificar el dolor en cuatro niveles, mediante el análisis de las señales utilizando la transformada en tiempo discreto Wavelet, así como representaciones de tiempo-frecuencia de estas ondas cerebrales. Como resultado principal, se evidencia que la mayor precisión se obtiene mediante la clasificación realizada con la onda β . Panavaranan y otros (Panavaranan y Wongsawat, 2013), definen las bandas de frecuencia de 8 a 12 Hz correspondiente a las ondas cerebrales α y de 13 a 30 Hz correspondiente a las ondas cerebrales β . A partir de estas ondas se analiza la transformada rápida de Fourier (FFT) con el fin de obtener la densidad espectral de potencia de la señal (PSD) normalizada. Se realiza clasificación mediante lógica difusa utilizando funciones de activación Gaussianas, y un clasificador de Máquina de Soporte Vectorial (SVM) para tres niveles de dolor. Mingxin y otros (Yu y Sun, 2020) por su parte implementaron Redes Neuronales Convolucionales (también llamadas ConvNets como contracción de su nombre en

inglés) tomando diferentes rangos de frecuencia de las señales α , β y γ para extraer diferentes representaciones temporales de las señales de EEG como características en cada uno de estos rangos logrando clasificar el dolor en tres niveles de dolor (ausencia de dolor, dolor moderado y dolor severo). Bai y otros (Bai y Zhang, 2016) utilizan los valores RMS de la señal EEG, a la cual se le ha aplicado previamente un filtro entre 1 y 30 Hz. La señal se analiza desde un segundo antes de un estímulo doloroso hasta medio segundo después de finalizar el estímulo, y por medio de regresión lineal se realiza la clasificación gracias a la comparación de los vectores previos y posteriores al estímulo. En (Kagita y Mitsukura, 2018), los autores evalúan presencia o ausencia de dolor ante dolor de tipo menstrual o debido a una migraña, utilizando la FFT para obtener la PSD, en valores de frecuencia entre 0,5 y 35Hz. Para la clasificación, los autores utilizan SVM. En (Cao y otros, 2020), los autores utilizan las características PSD y el análisis de fluctuación detenida multifractal (por sus siglas MF-DFA) de la señal de EEG y SVM como clasificador en un protocolo de pruebas en el cuál inducen estímulos dolorosos por medio de potenciales evocados por láser, logrando diferenciar entre dos niveles de dolor: presencia y ausencia de dolor. En (Nir y otros, 2010), los autores evalúan dolor inducido por estímulos térmicos en la mano, utilizando los picos de la frecuencia α (PAF por sus siglas en Inglés: "Peak Alpha Frequency"), utilizan análisis de varianza de mediciones repetidas (o RM-ANOVA por sus siglas en inglés) como clasificador de características, para distinguir 3 niveles diferentes de dolor.

En los trabajos presentados anteriormente, es común encontrar el uso de varios pares diferenciales de electrodos. En este artículo se presentan los resultados del análisis de las señales de EEG obtenidas mediante un par diferencial de electrodos, en experimentos basados en estímulos eléctricos para inducir dolor agudo. La clasificación permite obtener resultados con una precisión del 86,67%. Se muestra a continuación la metodología llevada a cabo para la adquisición de datos, el procesamiento de la señal y la clasificación de los datos. Así mismo, se presentan los principales resultados y la discusión.

2. Metodología

En este capítulo se presentará el experimento llevado a cabo para inducir dolor y medir la señal de EEG. Así mismo, se presenta el procesamiento que se le realiza a la señal con el fin de extraer características que permitan la clasificación entre dos niveles de dolor. Finalmente, se presenta el método utilizado para validar los algoritmos.

2.1. Descripción del Experimento

Se realiza un experimento en el que se induce dolor por medio de un experimento de electro-diagnóstico, el cual consiste en la medición continua de las señales de EEG mientras se induce un estímulo eléctrico que causa dolor, de manera no invasiva.


Población participante:

La población seleccionada para el procedimiento está conformada por 14 personas con un rango de edad de entre 18 y 33 años, las cuáles no presentan un cuadro clínico relacionado con estados de dolor crónico, epilepsia, estado de embarazo, diabetes, fibromialgia, complicaciones cardiocirculatorias, quemaduras, piel lesionada o alterada, entre otras, las cuáles podrían implicar algún tipo de complicación o riesgo en la salud de los voluntarios durante de la realización de la prueba. Previamente, se le explicó a los voluntarios el procedimiento, los participantes firmaron consentimiento informado y se les notificó que podían retirarse de la prueba en cualquier momento.

Experimento:

Esta prueba se basa en estímulos eléctricos inducidos con ayuda de un equipo marca Sierra Summit, el cuál es manipulado en todo momento por un médico especialista. El experimento consistió en la aplicación de corrientes eléctricas variables de baja magnitud y duración. Se empieza con valores desde 0 a 100 mA, con intervalos de aplicación de 50 a 1000 μ s, espaciados cada 30 s. La medición y toma de datos correspondiente a las señales de EEG durante el experimento se realiza utilizando la tarjeta Bitalino (r)evolution, con una tasa de muestreo de 1 kHz. La cual mediante un par diferencial de electrodos ubicados en Fp1, Fp2, de acuerdo con el sistema internacional 10-20, y con la referencia ubicada en A1, como se muestra en la figura 1. Adicionalmente, cada 20 s se les pedía a los participantes reportar el dolor percibido de acuerdo con la escala numérica de 0 a 10, donde 0 es no dolor y 10 es el máximo dolor percibido.

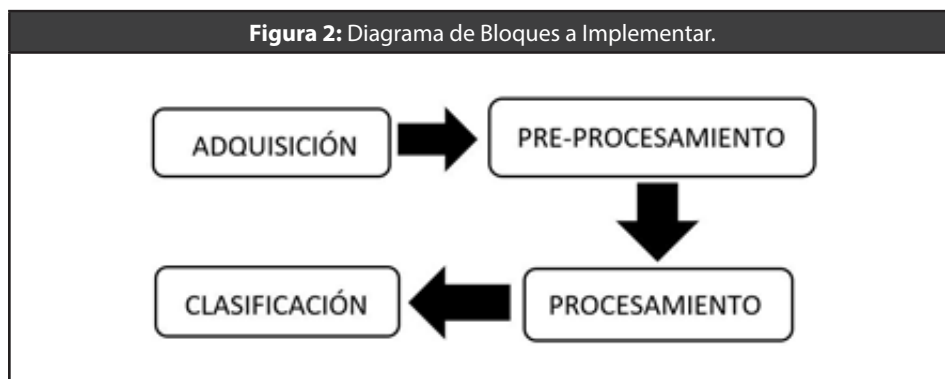
Figura 1: Ubicación de Electrodos para EEG según Sistema Internacional 10-20.



2.2. Procesamiento Digital de la señal de EEG

Posterior a la adquisición de datos, se realiza el procesamiento de la señal en el software MatLAB, la cual se realiza conforme al diagrama presentado en la Figura 2.

Figura 2: Diagrama de Bloques a Implementar.



Se realiza el análisis a partir de las ondas cerebrales, las cuales se diferencian a partir de sus rangos de frecuencia, como se muestra a continuación: Ondas Δ (1-5 Hz), Ondas Θ (4-7 Hz), Ondas α (8-13 Hz), Ondas β (13-30 Hz), y Ondas γ (30-70 Hz) (Tatum, 2021). Conforme a los resultados obtenidos por los autores en (Yu y Sun, 2020), se seleccionan las ondas α , β y γ . A continuación, se muestra el proceso que se realiza en cada una de las etapas del procesamiento.

Pre-procesamiento de Datos:

El pre-procesamiento de los datos obtenidos de la etapa de adquisición se caracteriza por la necesidad de eliminar una gran cantidad de componentes innecesarios, causados por aspectos como, movimientos del usuario que generan ruido en la señal. Esta etapa consta de tres filtros Butterworth pasa banda, para el análisis de las ondas α , β y γ de la señal EEG. Las frecuencias de corte de los filtros se muestran en la tabla 1.

Tabla 1: Frecuencias de corte para los filtros Butterworth			
Onda Cerebral	Orden	F. Corte Alta	F. Corte Baja
Alfa (α)	4	7,5 Hz	14 Hz
Beta (β)	5	13 Hz	33 Hz
Gamma (γ)	5	29 Hz	73 Hz

Extracción de Características:

Para la extracción de características, se utiliza el espectro de frecuencias normalizado de las ondas α , β y γ , en ventanas de tiempo de 5s alrededor de cada uno de los reportes del nivel de dolor experimentado por cada uno de los participantes, a los cuales se les preguntó cada 20s el valor NRS. De esta manera, la ventana de análisis inicia 2,5s antes de dicho reporte y termina otros 2,5s después del mismo. A partir de la PSD de las tres ondas cerebrales mencionadas se extraen sus respectivos valores RMS, así como la frecuencia a la cuál ocurre el valor pico de cada onda cerebral. A continuación, se explican matemáticamente cada uno de los procesos.

Transformada Rápida de Fourier: La transformada rápida de Fourier (o FFT por sus siglas en inglés) es un algoritmo utilizado para convertir una señal digital ($x(i)$) definida por N observaciones con un dominio temporal, en otra señal de dominio frecuencial (h) correspondiente al espectro frecuencial de la señal original, esta transformación se puede encontrar utilizando la ecuación 1.

$$X(h) = \sum_{i=0}^{N-1} (x(i)e^{-2jih\pi/N}) \quad (1)$$

Valor Medio Cuadrático: El valor medio cuadrático (o RMS por sus siglas en inglés) es un valor estadístico que se puede extraer de señales continuas o discretas, en el caso de las señales discretas se puede calcular el RMS de una señal x expresada por N observaciones a partir de la ecuación 2.

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

Clasificador:

Se define no dolor para valores reportados por los participantes por debajo de 4, de acuerdo con la escala NRS, y dolor para valores iguales o superiores a 4. De esta manera,

se etiquetan las salidas para posteriormente realizar la clasificación a partir de la señal de EEG. Una vez obtenidas las características de la señal de EEG se procede a entrenar el clasificador que permitirá, a partir de la evaluación de las características, definir entre dolor y no dolor. Se utiliza una red neuronal artificial de dos capas (con 50 neuronas en la capa oculta y 2 neuronas en la capa de salida, con función de activación exponencial normalizada y actualización de pesos con el método de gradiente conjugado escalado. Para el entrenamiento se utiliza el 70% de los datos, el 10% para la validación del modelo mejor entrenado y el 20% restante para evaluar el desempeño del clasificador.

2.3. Validación de Algoritmos

Para validar los algoritmos de extracción y clasificación de características se selecciona la matriz de confusión que expresa el comportamiento de las predicciones de los algoritmos propuestos contrastados con los valores reportados en el NRS (tomados como verdaderos) para cada uno de los niveles de dolor.

Matriz de Confusión:

La matriz de confusión es una representación gráfica simplificada, ampliamente utilizada en el campo de la inteligencia artificial para evaluar el desempeño de un algoritmo de reconocimiento de patrones, partiendo de los valores obtenidos para los valores verdaderos positivos (TP) (asociados a la ausencia de dolor), verdaderos negativos (TN) (asociados a la presencia de dolor), falsos positivos (FP) (cuando se clasifica como ausencia de dolor cuando si hay dolor), y falsos negativos (FN) (cuando se clasifica como dolor cuando no lo hay).

Métricas de Evaluación:

A partir de la matriz de confusión generada para indicar las predicciones de cada uno de los dos niveles de dolor, se procede a obtener los valores de precisión, especificidad, sensibilidad y exactitud a partir de las ecuaciones 3, 4, 5 y 6 respectivamente, como se definen a continuación.

La precisión obtenida indica el porcentaje de valores verdaderos positivos obtenidos con los datos de prueba, es decir la tasa de acierto del algoritmo para clasificar los datos como correspondientes a una ausencia de dolor. La especificidad expresa el porcentaje de verdaderos negativos obtenidos, es decir el porcentaje de aciertos de estos al clasificar presencia de dolor. La sensibilidad expresa el porcentaje de aciertos de los algoritmos para obtener un resultado de ausencia de dolor entre los datos que se sabe que pertenecen a este nivel de dolor. Por último, la exactitud expresa el porcentaje de valores verdaderos que tuvieron resultados correctos para cada uno de los grupos, respecto al total de datos clasificados.

3. Resultados y discusión

Posterior al entrenamiento y teniendo en cuenta los valores para validación del algoritmo, se logra una precisión del 68,42%, una especificidad del 62,50%, una sensibilidad del 86,67% y una precisión del 74,19%. Estos valores indican que el algoritmo propuesto tiene una buena tasa de aciertos para predecir ausencia de dolor, escenario que no es tan favorable para la presencia de dolor, sin embargo, realizando el balance entre los dos niveles de dolor mencionados, se obtiene una precisión que permiten en general considerar que el algoritmo utilizado permite realizar una buena clasificación entre dolor y no dolor. Este caso se puede mejorar con una mayor cantidad

de datos para entrenamiento y test. Se utilizaron otros algoritmos de clasificación bajo el mismo principio de entrenamiento y validación mediante el uso del toolbox de MatLab: *Classification Learner*, obteniendo los resultados de la tabla 2.

Tabla 2: Métricas de evaluación considerando otros tipos de clasificadores.

Algoritmo de clasificación	Métrica de evaluación			
	Precisión(%)	Especificidad (%)	Sensibilidad (%)	Exactitud (%)
KNN Cúbico	66,7	33,33	85,71	65,22
Discriminante lineal	63,64	33,33	75,00	58,70
Regresión logística	63,64	33,33	75,00	58,70
SVM Lineal	62,86	27,78	78,57	60,87
SVM Cúbico	72,22	72,22	46,43	41,30

Donde se encontró que para los diferentes algoritmos de ML se obtuvieron algunas métricas con mejores desempeños, sin embargo, el balance de aciertos entre los dos niveles de dolor no fue lo suficientemente alto para considerarlo más efectivo frente a la RNA propuesta para la clasificación de los dos niveles de dolor. Adicionalmente se realizó un análisis de los trabajos previos consultados durante el desarrollo del presente trabajo para comparar los diferentes algoritmos de clasificación de dolor en términos de los pares diferenciales requeridos para su correcta implementación, así como el tipo de estímulo utilizado para inducir dolor, y finalmente la cantidad de niveles de dolor para clasificación. Se encontró que en general el tipo de estímulo empujado es térmico como el trabajo encontrado en (Bai y Zhang, 2016), por otro lado, se utiliza más de un par diferencial de electrodos, por ejemplo en (Yu y Dong, 2020) y en (Panavaranan y Wongsawat, 2013) se utilizan 16 pares de electrodos con dos electrodos de referencia, en (Cao y otros, 2020) se utilizan 7 pares con 2 electrodos de referencia, lo que le permite a los autores obtener en general una mayor precisión en la clasificación. Adicionalmente, varios trabajos realizan clasificación binaria como los encontrados en (Cao y otros, 2020), pero algunos autores trabajan clasificación en más de dos niveles, como (Yu y Dong, 2020), lo que se plantea como un trabajo a futuro.

De esta manera, se obtuvo un sistema de detección de dolor capaz de discernir entre ausencia y presencia de dolor con equipos de bajo costo y pocos electrodos disponibles, brindando una alternativa que puede apoyar el método clínico de manera rápida y no invasiva, la cual puede incrementar su fiabilidad al utilizar equipos con mayor cantidad de pares diferenciales disponibles para adquirir datos de EEG.

4. Conclusiones

En este trabajo se planteó un clasificador binario para detección de dolor basado en características como el valor RMS y la frecuencia pico de la PSD de señales EEG, basado en las ondas alfa, beta y gamma. De esta manera, se puede obtener un sistema de detección de dolor con ayuda de un solo par diferencial de medición de EEG y métodos de clasificación de características de las diferentes ondas cerebrales, como redes neuronales artificiales. Se recomienda la implementación de filtros digitales adicionales a los análogos ya incluidos en los sistemas de adquisición de datos, con el objetivo de eliminar componentes no deseados en las señales obtenidas como por ejemplo impulsos

por movimientos de los ojos, parpadeos, entre otros. Los resultados pueden mejorarse al incrementar los pares diferenciales, lo que incrementa el costo de la adquisición de datos, así como el gasto computacional para el procesamiento de los datos.

5. Agradecimientos

Los autores agradecen a la Vicerrectoría de Investigaciones de la Universidad Militar Nueva Granada por la financiación del proyecto INV-ING-2991

6. Referencias

- Alazrai, R., Daoud, M.I., Momani, M., Khudair H.A. (2019). EEG-based tonic cold pain recognition system using wavelet transform. In *Neural Computing and Applications* , (pp. 3187-3200).
- Bai, Y., Hu, Y., & Zhang, Z. (2016). Spontaneous EEG-based normalization of pain-evoked neural responses: Effect on improving the accuracy of pain prediction. In *2016 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA)* (pp. 1-4). IEEE.
- Bonotis, P. A., Tsouros, D. C., Smyrlis, P. N., Tzallas, A. T., Giannakeas, N., Glavas, E., & Tsipouras, M. G. (2019). Automated Assessment of Pain Intensity based on EEG Signal Analysis. In *2019 IEEE 19th International Conference on Bioinformatics and Bioengineering (BIBE)* (pp. 583-588). IEEE.
- Cao, T., Wang, Q., Liu, D., Sun, J., & Bai, O. (2020). Resting state EEG-based sudden pain recognition method and experimental study. *Biomedical Signal Processing and Control*, 59, 101925.
- Grabowski, S. R., & Tortora, G. J. (2000). *Principles of anatomy and physiology*. New York/Chichester: Wiley.
- Kagita, J., & Mitsukura, Y. (2018). Quantification of pain degree by frequency features of single-channelled EEG. In *2018 IEEE 15th International Workshop on Advanced Motion Control (AMC)* (pp. 359-363). IEEE.
- Tatum IV, W. O. (2021). *Handbook of EEG interpretation*. Springer Publishing Company.
- Tortora, G. J., & Nielsen, M. T. (1995). *Human Anatomy*. Harper Collins College Pub.
- Ilana, E. (1979). Pain terms; a list with definitions and notes on usage. *Pain*, 6, 249.
- Manworren, R. C., & Stinson, J. (2016). Pediatric pain measurement, assessment, and evaluation. In *Seminars in pediatric neurology* (Vol. 23, No. 3, pp. 189-200). WB Saunders. DOI: <https://doi.org/10.1016/j.spen.2016.10.001>.
- Nir, R. R., Sinai, A., Raz, E., Sprecher, E., & Yarnitsky, D. (2010). Pain assessment by continuous EEG: association between subjective perception of tonic pain and peak frequency of alpha oscillations during stimulation and at rest. *Brain research*, 1344, 77-86.
- Panavaranan, P., & Wongsawat, Y. (2013). EEG-based pain estimation via fuzzy logic and polynomial kernel support vector machine. In *The 6th 2013 Biomedical Engineering International Conference* (pp. 1-4). IEEE.
- Yu, M., Sun, Y., Zhu, B., Zhu, L., Lin, Y., Tang, X., ... & Dong, M. (2020). Diverse frequency band-based convolutional neural networks for tonic cold pain assessment using EEG. *Neurocomputing*, 378, 270-282.