

## Tratamiento de señales electroencefalográficas de imaginación motora con fines de clasificación

Alexis Edmundo Gallegos Acosta, María Dolores Torres Soto,  
Aurora Torres Soto, Eunice Esther Ponce de León Sentí

Benemérita Universidad Autónoma de Aguascalientes,  
México

alexisedm@gmail.com,  
{mdtorres, atorres, eponce}@correo.uaa.mx

**Resumen.** En este artículo se presenta un análisis de la influencia del tratamiento de señales electroencefalográficas en el desempeño de un clasificador de máquina de soporte vectorial (SVM), cuyo objetivo fue la distinción de señales de imaginación motora (“abrir” y “cerrar” la mano derecha). El tratamiento consistió en el cálculo de la transformada rápida de Fourier (FFT) y la normalización Z-score. Esto debido a que las señales crudas poseen la suma de toda la actividad cerebral que incluye actividades fisiológicas como el movimiento ocular, cardíaca, la respiración, entre otros. Así, el objetivo de la selección de una técnica de tratamiento de datos permite la extracción de características que facilitan su posterior clasificación o evaluación. Las señales con imaginación motora que conforman el conjunto de datos utilizado para este artículo se obtuvieron por medio del dispositivo BCI Emotiv EPOC+ de 14 canales. Como resultado se presenta que el conjunto de datos transformado por FFT y normalizado obtiene mejor exactitud y precisión, a la vez que mantiene un buen equilibrio en la distinción de las clases mencionadas.

**Palabras clave:** Señales electroencefalográficas, aprendizaje automático, transformada de Fourier, imaginación motora.

### Electroencephalographic Signal Processing of Motor Imagery for Classification Purposes

**Abstract.** This paper presents an analysis of the influence of the electroencephalographic signal processing on the performance of a support vector machine (SVM) classifier, whose objective was the distinction of motor imagery signals ("opening" and "closing" the right hand). The treatment consisted of fast Fourier transform (FFT) computation and normalization Z-score. This is because the raw signals have the sum of all the brain activity that includes physiological activities such as eye movement, cardiac, breathing, among others. In this way, the purpose of the selection of a data processing technique allows the extraction of characteristics that facilitate their subsequent classification or evaluation. The motor imagery signals that make up the data set used for this article were obtained by means of the 14-channel BCI Emotiv EPOC+ device. As a result, the FFT-transformed and normalized data set obtains better accuracy and precision, while maintaining a good balance in the distinction of the mentioned classes.

**Keywords:** Electroencephalographic signals, machine learning, Fourier transform, normalization.

## **1. Introducción**

El electroencefalograma (EEG) es un dispositivo desarrollado con el objetivo de registrar la actividad eléctrica del cerebro y que, en la actualidad, es utilizado de forma rutinaria para el diagnóstico de patologías y trastornos asociados al cerebro [1, 2]. La señal capturada por un dispositivo EEG es compleja debido a que se constituye de la suma de la actividad de diferentes poblaciones neuronales incluyendo actividades fisiológicas como el movimiento ocular, la respiración, la actividad cardiaca, entre otras [2, 3].

Las señales EEG poseen distintas propiedades como forma, amplitud, contenido frecuencial, etc., y de ellas se puede extraer información útil sobre el estado mental asociado a actividades motoras, sensoriales, estadias del sueño o diferentes enfermedades mentales [4].

En medicina el análisis de patrones en señales EEG se realiza por medio de un proceso de reconocimiento visual que requiere de entrenamiento para distinguir patrones y su asociación con diferentes enfermedades convirtiéndose así, en un proceso subjetivo [4]. Como consecuencia, se han desarrollado nuevas tecnologías y técnicas de procesamiento matemático que buscan mejorar la interpretación del comportamiento de las señales y que, a su vez, faciliten su análisis y sistematización [2, 4, 5].

A la fecha existen diferentes trabajos en la literatura que tienen el objetivo de proponer modelos que permitan el análisis de señales EEG con diferentes propósitos como la detección de enfermedades, detección de movimientos, detección de reacciones de acuerdo con distintos estímulos, control de dispositivos, etc. Por ejemplo, en [6] se muestra la planeación de una interfaz cerebro-computadora BCI que permite la detección de emociones.

Por su parte, [5] busca la detección de movimientos oculares, musculares y cognitivos. Mientras que [4] estudia diferentes técnicas de procesamiento de señales para la detección de ritmos cerebrales y crisis epilépticas. Además, existen proyectos que buscan convertir las señales EEG, en conjunto con sistemas BCI, en canales alternativos de comunicación y control como lo realizado en [7], identificando señales de imaginación motora; es decir, el análisis de actividades neuronales asociadas a movimiento mental sin necesidad de la intervención física de los nervios y músculos del cuerpo.

El presente artículo tiene como objetivo analizar la influencia de tratamiento de señales EEG con imaginación motora (“abrir” y “cerrar” la mano derecha), en el desempeño de un modelo de máquina de soporte vectorial (SVM); es decir, un clasificador que tiene el propósito de distinguir señales EEG con la intención de abrir la mano de las señales con la intención de cerrar la mano derecha.

Dicho tratamiento de datos se realizó por medio del cálculo de la transformada rápida de Fourier (FFT), una de las herramientas de extracción de características más populares en el análisis de series temporales [5, 8].

Como siguiente paso, se hace uso de la normalización Z-score, que permite a los algoritmos de aprendizaje automático encontrar tendencias evitando la existencia de diferencias drásticas entre las características analizadas. De manera que los datos tomen una misma escala y sean igualmente importantes al momento de realizar una clasificación mediante un algoritmo computacional.

Como resultado se tiene que, como se menciona en [9], la normalización de los datos es imprescindible para llevar a cabo la clasificación de objetos. Además, de que en conjunto con el cálculo de la transformada de Fourier permiten obtener incluso, mejores resultados en el desempeño de un clasificador como las máquinas de soporte vectorial.

A continuación, se abordan los conceptos importantes para este trabajo como la imaginación motora, las señales electroencefalográficas, la transformada de Fourier y el aprendizaje automático. Después, se procede a exponer los materiales y métodos seguidos para lograr el objetivo de artículo para, finalmente, presentar los resultados obtenidos, así como las conclusiones a las que se llegaron.

## **2. Conceptos relacionados**

### **2.1. Imaginación motora**

La imaginación motora (motor imagery), intención de movimiento o práctica mental del movimiento, ha sido fundamental en avances científicos bajo el contexto de rendimiento deportivo y rehabilitación [10, 11]. Se trata de un proceso cognitivo-perceptivo que consiste en la realización mental de movimientos que no van acompañados de ningún tipo de actividad muscular o periférica [12].

De acuerdo con Mokienko et al en [12], se distinguen dos tipos de imaginación motora: las formas visuales y las formas cinestésicas de imágenes motrices. En la forma visual, el sujeto produce una imagen de su movimiento simulando verse a sí mismo en tercera persona; mientras que, en la segunda forma, el sujeto genera la sensación cinestésica del movimiento.


La práctica de imaginación motora permite el desarrollo motor y aprendizaje de habilidades motrices evidenciando incluso, ganancia de fuerza en grupos musculares específicos. Desde el punto de vista médico, ha tenido resultados positivos en la rehabilitación en pacientes con condiciones neuromusculares.

Por ejemplo, pacientes con accidentes cerebrovasculares en los que la imaginación motora funciona como una “puerta trasera” al sistema motor y a la rehabilitación en todas las etapas de ictus al mantener el uso de impulsos voluntarios [13], además de que se ha demostrado que la imaginación motora activa zonas del cerebro que también están implicadas en la preparación y ejecución del movimiento físico [12].

Las ciencias computacionales también han estudiado la imaginación motora para desarrollo de interfaces cerebro-computadora (BCI) las cuales, han ganado una amplia atención en los últimos años. Los sistemas BCI basados en imaginación motora más importantes, son aquellos que involucran aplicaciones en tiempo real como la escritura sin contacto, brazos protésicos, sistemas de realidad virtual, control de dispositivos, etc. En este tipo de sistemas la clasificación de los datos de imaginación motora es el núcleo de este tipo de sistemas, dando como resultado el diseño de diferentes marcos de trabajo para mejorar el procesamiento de este tipo de datos [7, 14].

### **2.2. Señales electroencefalográficas**

La electroencefalografía es una técnica que permite el registro de la actividad cerebral (señales EEG). “Las señales registradas corresponden a una mezcla de



**Fig. 1.** Transformada discreta de Fourier [17].

información cerebral, así como artefactos fisiológicos (movimientos oculares, musculares, latido cardiaco, sudor) o técnicos (líneas de alimentación, desconexión de electrodos)” [15].

La captura de señales EEG es una técnica no invasiva que, en medicina es utilizada para la búsqueda de patrones anormales que identifiquen alguna patología. Esto se debe a que la actividad cerebral forma un patrón reconocible [16].

Para la elaboración de este artículo, se utilizó el dispositivo EMOTIV Epor+ con tasa de muestreo de 128Hz por medio de 14 canales (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4) distribuidos en el cuero cabelludo bajo el estándar 10-20, el cual es un método internacional que describe la ubicación de los electrodos de un dispositivo de electroencefalograma [17].

### 2.3. Transformada rápida de Fourier (FFT)

La transformada de Fourier (FT) es una de las herramientas más poderosas en el análisis de señales y crucial en muchas aplicaciones como la computación científica y la ciencia de datos [18]. El análisis de Fourier permite expresar una función como la suma de sus componentes periódicas, es decir, descompone la función en una serie de funciones trigonométricas más simples [18], [19], que, al sumarse tendrían la forma exacta de la señal original [20].

Existe la posibilidad de analizar señales cuya representación es exacta por medio de una suma finita de  $N$  senoides. Por el contrario, existen otras con las cuales solo es posible realizar una suma parcial para obtener una aproximación adecuada cuyo error tiende a cero al considerar más términos o frecuencias [20]. Es decir, dada una señal periódica con periodo  $T$ , su aproximación está dada por la suma parcial de la serie de Fourier de  $f(t)$ , como se muestra la ecuación (1) [20]:

$$f(t) \cong a_0 + \sum_{n=1}^N a_n \cos(n\omega_0 t) + \sum_{n=1}^N b_n \sin(n\omega_0 t) \tag{1}$$

donde  $a_0$ ,  $a_n$  y  $b_n$  son los coeficientes trigonométricos de Fourier, mientras que  $\omega_0$  es la frecuencia.

El cálculo de la transformada de Fourier con gran cantidad de muestreos se vuelve complejo dada la gran cantidad de operaciones a realizar provocando que el tiempo requerido también incremente [21]. Para ello se puede aplicar el algoritmo de la transformada rápida de Fourier (FFT) o transformada discreta de Fourier (DFT).

Sin embargo, cabe aclarar que tanto la FFT como la DFT son utilizadas en la literatura de forma indiferente, a pesar de ello, el FFT es un algoritmo que calcula la transformada discreta de Fourier [18].

La transformada discreta de Fourier realiza el análisis espectral de una señal, trasladándose del espacio de tiempo discreto al espacio de frecuencias donde es posible obtener información de las componentes frecuenciales predominantes de una señal [22].

La DFT transforma la señal del dominio del tiempo de  $N$  puntos en dos señales nuevas (parte real e imaginaria) en el dominio de la frecuencia de  $N$  puntos [17] (ver Fig. 1). Este nuevo dominio de la señal descompone la señal en su correspondiente sinusoidal de diferentes frecuencias [23].

La transformada rápida de Fourier (FFT) para una señal discreta  $x_n$ , donde  $k$  es cada valor discreto de la señal, está dada por la ecuación (2) [23]:

$$y[k] = \sum_{n=0}^{N-1} e^{-2\pi j \frac{kn}{N}} x[n] \quad \text{con } k = 0, 1, \dots, N-1 \quad (2)$$

La transformada de Fourier presenta características importantes como la linealidad, esto es, posee la propiedad distributiva respecto de la suma. Por otra parte, se trata de una función simétrica conjugada lo que, beneficia el cálculo de la magnitud de los puntos en un periodo completo, pues solo es necesario calcular los  $N/2+1$  primeros puntos. Finalmente, si la señal sufre una rotación en un ángulo determinado, su transformada también se verá afectada por una rotación del mismo ángulo [24].

#### 2.4. Aprendizaje automático

El aprendizaje automático o machine learning (ML) es una rama de la inteligencia artificial encargada del desarrollo de técnicas que permiten a las computadoras aprender [25]. Es decir, es un área que dedica su estudio a la construcción de programas computacionales que tengan la habilidad de mejorar su desempeño en alguna tarea específica gracias a la experiencia [26, 27].

Un programa informático aprende de un conjunto de tareas, si su medida de desempeño mejora con la experiencia [27]. Es decir, se dice que un sistema aprende de forma automática si, para resolver un problema, es capaz de tomar decisiones con base en la experiencia acumulada, incluso se busca que estos sistemas sean capaces de trabajar con una gran cantidad de datos de entrada, los cuales pueden contener ruido e inconsistencias [28].

Los algoritmos de ML son capaces de encontrar patrones a partir de datos previamente suministrados, lo que permite la creación de modelos de predicción y toma de decisiones [29].

Así, la calidad y la cantidad de la información con la que se entrena este tipo de algoritmos es crucial, pues se trata de métodos matemáticos sofisticados y métodos de búsqueda en grandes escalas que requieren de estructuras de representación del conocimiento adecuada, para agilizar la identificación de hechos relevantes [29, 30].

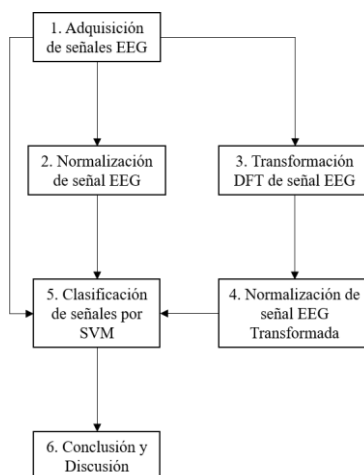


Fig. 2. Metodología.

Nilsson, en su libro *Introduction to Machine Learning* [31], enlista los requerimientos que conforman un sistema de aprendizaje automático [26, 31]:

- Selección del tipo de entrenamiento.
- Definición de la función objetivo a aprender.
- Definición de la representación de la función objetivo.
- Selección del algoritmo de aprendizaje.


En la literatura se pueden encontrar diversos algoritmos de aprendizaje automático como: los árboles de decisión, las máquinas de soporte vectorial, máxima entropía, naive Bayes, etc. [26]. Para este trabajo se implementó un modelo de máquina de soporte vectorial que permite modelar señales EEG con imaginación motora de abrir y cerrar la mano derecha.

### 3. Materiales y métodos

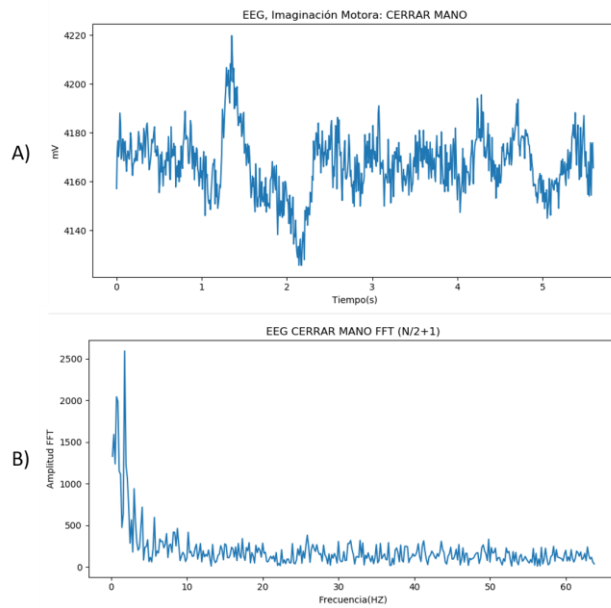
En la Fig. 2 se muestra la metodología que se siguió para la elaboración de este artículo. Este procedimiento tiene el objetivo de analizar el desempeño de un modelo de máquina de soporte vectorial (SVM) al entrenarse con cuatro bases de datos. La primera de ellas es la base de datos crudos de señales EEG con imaginación motora; la segunda, es el mismo conjunto de datos, pero tratados por medio de una normalización Z-score.

Por su parte, el tercer conjunto de datos corresponde a la señal cruda procesada por medio de la transformada rápida de Fourier (FFT) y la última corresponde a una base de datos normalizada por medio de la normalización Z-score de los datos transformados anteriormente por la FFT.

La implementación del algoritmo de máquina de soporte vectorial, así como la implementación y representación de la transformada rápida de Fourier se realizaron con las librerías disponibles de Python.



**Fig. 3.** Protocolo de captura de señales EEG con imaginación motora.



**Fig. 4.** (A) Señal en crudo. (B) Señal transformada FFT.

El primer paso de metodología consta de la adquisición de las señales EEG en crudo. Este paso de la metodología se realizó empleando el dispositivo de EEG Emotiv EPOC+ de 14 canales (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4) con una tasa de muestreo de 128 muestras por segundo. Además, se contó con el software de captura Cykit [32], de acceso libre, que permitió el registro de las señales de imaginación motora correspondientes a abrir y cerrar la mano derecha en archivos csv para su tratamiento posterior.

Para realizar el muestreo de las señales EEG con imaginación motora, se siguió un protocolo de captura basado en el presentado por Paredes et al en [17]. Como se muestra en la Fig.3, la captura consta de 20 segundos en los que el sujeto de prueba se concentra en una de las intenciones solicitadas (abrir o cerrar la mano derecha). La captura de la señal inicia cinco segundos después de que el sujeto de prueba inició su concentración y se detiene cinco segundos antes de finalizar la prueba.

De esta manera es posible tener mayor seguridad de que se captura la intención o imaginación del movimiento de la mano. Una vez terminada la captura de imaginación motora, se cuenta con un archivo .csv con los registros de los 14 canales del dispositivo de Emotiv. Para este caso, la base de datos constó de 1,283 registros obtenidos a

conveniencia de un solo sujeto de prueba, de los cuales, 566 corresponden a la imaginación motora de abrir la mano derecha y 717 registros corresponden a cerrar la mano, teniendo dos conjuntos disjuntos de señales EEG.

El segundo paso fue trasladar una copia de la base de datos cruda a una escala común debido a la magnitud de los valores que toma cada vector de las 14 canales. De manera paralela, se aplicó una transformada discreta de Fourier como tercer paso, descrita en el apartado 2.3. En la Fig.4 se expone la gráfica de la señal en crudo del canal AF3 (gráfica A) correspondiente a la imaginación de movimiento de abrir la mano.

Por su parte, la gráfica B muestra la aplicación de la transformada rápida de Fourier para calcular la transformada discreta de Fourier. Como se puede observar se aprovecha la propiedad de simetría ya comentada en el apartado 2.3. Al igual que el conjunto de datos en crudo, el conjunto de datos tratado con la transformada rápida de Fourier fue trasladado a una escala común por medio de la normalización Z-score que corresponden al cuarto paso de la metodología de la Fig. 2.

En este punto, se cuenta con cuatro conjuntos de datos: las señales en crudo, las señales en crudo normalizadas, señales transformadas a Fourier y señales transformadas normalizadas. Dichos conjuntos de datos fueron utilizados para entrenar y validar un modelo de máquina de soporte vectorial (SVM) para así, analizar el desempeño de este trabajando con cada uno de los conjuntos de datos.

El desempeño del modelo se midió mediante las métricas de desempeño tradicionales: exactitud, precisión, sensibilidad, especificidad y puntuación F1 la cual, resume la precisión y la sensibilidad de los modelos en una sola métrica, siendo de mayor utilidad cuando existe un desbalance entre las clases [33].

La Tabla 1, muestra los parámetros utilizados para construir cada uno de los modelos SVM probados cada conjunto de datos. Los valores de Kernel, Gamma y C fueron definidos de acuerdo con los resultados observados en [34].

Cada modelo fue replicado 30 veces para analizar su comportamiento. En siguiente apartado se exponen los resultados obtenidos.

## **4. Resultados**

Como ya se ha mencionado, se entrenaron y validaron los cuatro modelos de SVM. Cada modelo fue replicado 30 veces para valorar su desempeño. Así mismo, cada réplica seleccionó su propio conjunto de datos para entrenamiento y validación en porcentajes de 80% y 20% respectivamente. Como medidas de desempeño se utilizaron las métricas de exactitud, precisión, sensibilidad, especificidad y puntuación F1.

En la Fig. 5 se muestra el comportamiento de la exactitud que presentaron los modelos de SVM. Los datos en crudo y los datos tratados con transformada de Fourier presentan valores muy similares rondando entre el 40% y 65%.

En cambio, los conjuntos de datos normalizados presentan una mejor exactitud. Sin embargo, en este caso los datos transformados y normalizados son claramente superiores al mantenerse cerca del 100% durante el proceso de replicado. Esto quiere decir, que estos modelos pueden identificar de manera efectiva señales tanto de “abrir” como de “cerrar” la mano.




Fig. 5. Exactitud (Accuracy).

Tabla 1. Parámetros del modelo SVM.

Kernel	Valor Gamma	Valor C
Rbf	0.04	200

La métrica siguiente es la precisión que, en este caso mide la proporción de señales correspondientes a “abrir la mano” que fueron correctamente clasificadas. Como se puede observar en la Fig.6, el comportamiento es similar al de la Fig.5, mostrando que los datos normalizados y transformados normalizados presentan una mejor distinción de la imaginación motora de abrir la mano.

La Fig.7 muestra el desempeño de los modelos SVM según la métrica de sensibilidad que indica la capacidad del modelo para distinguir las señales de “abrir la mano” de las señales de “cerrar la mano”. La gráfica de la Fig. 7 muestra que los modelos que trabajaron con datos crudos y datos transformados son perfectamente capaces de clasificar señales con la intención de abrir la mano, incluso, empatan con un 100% durante todo el proceso de replicado por lo que se aprecia una sola línea.

Al igual que en el caso de la exactitud, las réplicas del modelo SVM que trabajaron con el conjunto de datos transformados y normalizados tienen un mejor comportamiento que el modelo que trabajó con los datos crudos normalizados llegando incluso, a igualar a los modelos con datos crudos y transformados en algunas de las réplicas.

La especificidad mide la capacidad del modelo de distinguir las señales de “cerrar la mano” de las señales de “abrir la mano”. A diferencia del desempeño obtenido en la métrica de sensibilidad, los modelos que trabajaron con datos crudos y normalizados son, prácticamente incapaces de reconocer una señal con la intención de cerrar la mano (ver Fig. 8). En cuanto a los modelos SVM que trabajaron con los conjuntos normalizados mantienen un comportamiento similar al caso anterior, lo que significa que existe un equilibrio entre su capacidad de distinguir una señal de la otra.

Finalmente, se analiza en la Fig. 9 la métrica de la puntuación F1. Aquí se puede observar que una vez más los modelos que trabajaron con conjuntos normalizados




Fig. 6. Precisión (Precision).




Fig. 7. Sensibilidad (Recall).

tienen un muy buen nivel de precisión y sensibilidad, siendo superior el modelo con datos transformados y normalizados.

## 5. Conclusiones y trabajo a futuro

Frente a lo expuesto en este artículo, se concluye que la calidad de los datos con los que se alimenta un algoritmo de aprendizaje automático es de alta importancia, pues permite agilizar su análisis y procesamiento de datos.

Es por ello, que elegir un buen algoritmo de extracción de características, como la transformada de Fourier, es clave para obtener mejores resultados en el desempeño de los algoritmos de clasificación. En este caso la FFT resulta conveniente pues asume que los datos son localmente estacionarios y los datos utilizados de las señales, aunque no lo son, corresponden a muestras obtenidas en un tiempo finito específico. Asimismo, la utilización de algún método de normalización como la Z-score es imprescindible pues evita la existencia de sesgo en la clasificación de objetos al trasladar cada una de las características a una escala común. De esta manera, como se muestra en el apartado de




Fig. 8. Especificidad (Specificity).




Fig. 9. Puntuación F1 (F1 Score).

resultados, ambas herramientas favorecen un alto desempeño por parte del modelo de máquina de soporte vectorial en cada una de las métricas de evaluación utilizadas.

Como trabajo a futuro se tiene la construcción de una base de datos mayor con el muestreo de una mayor cantidad de sujetos de prueba. Además de experimentar con más herramientas de extracción de características como la transformada Wavelet y dimensión fractal. Adicionalmente, se pretende probar su desempeño en algoritmos de aprendizaje automático como las redes neuronales artificiales (RNA), random forest (RF), naive Bayes, entre otros.

## Referencias

1. Espinosa, L.: Electroencefalografía inalámbrica: Una mirada actual y propuesta de sistema portátil. Universidad Técnica Federico Santa María, Chile, 2016, [http://profesores.elo.utfsm.cl/~agv/elo323/2s15/projects/reports/LeonardoEspinosa\\_WirelessEEG.pdf](http://profesores.elo.utfsm.cl/~agv/elo323/2s15/projects/reports/LeonardoEspinosa_WirelessEEG.pdf)
2. Urrestarazu, E., Iriarte, J.: Mathematical analyses in the study of electroencephalographic

- signals, *Rev. Neurol.*, vol. 41, no. 5, pp. 423–434 (2005) <https://dadun.unav.edu/handle/10171/22783>
3. Torres-García A. A., Reyes-García, C. A., Villaseñor-Pineda, L., Ramírez-Cortés, J. M.: Análisis de señales electroencefalográficas para la clasificación de habla imaginada. *Revista Mexicana de Ingeniería Biomédica*, vol. 34, no. 1, pp. 23–39 (2013) doi: 10.35537/10915/32602
  4. Bermúdez-Cicchino, A. N.: Técnicas de procesamiento de EEG para detección de eventos. Universidad Nacional de La Plata (2013) doi: 10.35537/10915/32602
  5. Gómez-Figueroa, L. J.: Análisis de señales EEG para detección de eventos oculares, musculares y cognitivos. Universidad Politécnica de Madrid, España (2016)
  6. Aparicio-García, R. S., Juárez-Gracia, G., Álvarez-Cedillo, J. A., Sandoval- Gutiérrez., J., Tovar-Corona, B.: Método de extracción y selección de características para la implementación de una interfaz cerebro-computadora en detección de emociones. *Dyna New Technol*, vol. 4, no. 1, pp. 14 (2017) doi: 10.6036/nt7829
  7. Sreeja, S. R., Rabha, J., Nagarjuna, K. Y., Samanta, D., Mitra, P., Sarma, M.: Motor imagery EEG signal processing and classification using machine learning approach. In: *Proceedings of International Conference on New Trends in Computing Sciences* (2017) doi: 10.1109/ICTCS.2017.15
  8. Martín-Sánchez, J. L.: Aportaciones al diseño de interfaces persona-máquina utilizando señales EEG. Universidad de Alcalá, Alcalá (2017)
  9. Lin, J., Keogh, E., Lonardi, S., Chiu, B.: A symbolic representation of time series, with implications for streaming algorithms. In: *Proceedings of the 8th ACM SIGMOD workshop on Research issues in data mining and knowledge discovery DMKD'03* (2003) doi: 10.1145/882082.882086
  10. Fernández-Gómez, E., Sánchez-Cabeza, Á.: Imaginería motora: revisión sistemática de su efectividad en la rehabilitación de la extremidad superior tras un ictus. *Rev. Neurol.*, vol. 66, no. 05, (2018) doi: 10.33588/rn.6605.2017394
  11. MacIntyre, T. E., Madan, C. R., Moran, A. P., Collet, C., Guillot, A.: Motor imagery, performance and motor rehabilitation. *Progress in Brain Research*, vol. 240, S. Marcora and M. Sarkar, Eds. Elsevier, pp. 141–159 (2018) doi: 10.1016/bs.pbr.2018.09.010
  12. Mokienko, O. A., Chernikova, L. A., Frolov, A. A., Bobrov, P. D.: Motor imagery and its practical application, *Neurosci. Behav. Physiol.*, vol. 44, no. 5 (2014) doi: 10.1007/s11055-014-9937-y
  13. Dickstein, R., Deutsch, J. E.: Motor imagery in physical therapist practice, *Phys. Ther.*, vol. 87, no. 7, pp. 942–953, (2007) doi: 10.2522/ptj.20060331
  14. Kumar, S., Sharma, A., Mamun, K., Tsunoda, T.: A deep learning approach for motor imagery EEG signal classification. In: *2016 3rd Asia-Pacific World Congress on Computer Science and Engineering* (2016) doi: 10.1109/APWC-on-CSE.2016.017
  15. Santillan-Guzman, A., Ramírez-Urriarte, H. Z., Oliveros-Oliveros, J. J.: Morin Castillo, M. M., Ramírez-Díaz, H.: Interfaz gráfica intuitiva para el procesamiento de señales EEG. In: *Memorias DEL Congr. Nac. Ing. Biomédica*, vol. 5, no. 1, pp. 146–149 (2018) doi: 10.24254/CNIB.18.20
  16. Tombesi, S.: Análisis de electroencefalograma con transformada de Fourier. (2012)
  17. Zea-Paredes, D. A., Arévalo-Villacrés, J. M.: Sistema de detección de la intención de dos movimientos de la mano a través del procesamiento de señales EEG. Universidad de Cuenca, Cuenca, Ecuador (2020)
  18. MacLeod, C.: Fourier transforms with `scipy.fft` python signal processing. *Real Python* (2020) <https://realpython.com/python-scipy-fft/>
  19. Scipy, Fourier transforms (`scipy.fft`), *Scipy.org* (2021) <https://docs.scipy.org/doc/scipy/reference/tutorial/fft.html>.

20. Urquiza, N.: Aplicación de las series de Fourier a un circuito excitado por una señal periódica. Bahía Blanca, Argentina, (2011) <http://lcr.uns.edu.ar/fvc/NotasDeAplicacion/FVC-NicolásUrquiza.pdf>.
21. Supervielle-Brouqués, F. G.: Digitalización del sonido. Bahía Blanca, Argentina (2011) <http://lcr.uns.edu.ar/fvc/NotasDeAplicacion/FVC-GastonSupervielle.pdf>.
22. Revel-Luna, D.: Transformada discreta de fourier: Análisis de señales en tiempo real (2020)
23. Medina, B., Sierra, J. E., Ulloa, A. B.: Técnicas de extracción de características de señales EEG en la imaginación de movimiento para sistemas BCI Extraction techniques of EEG signals characteristics in motion imagination for BCI systems, *Espacios*, vol. 39, no. 22, pp. 36–48 (2018) <https://www.revistaespacios.com/a18v39n22/18392236.html>
24. Araujo, C. I.: Transformada discreta de Fourier propiedades, aplicaciones, ejemplos. *lifeder.com* (2019) <https://www.lifeder.com/transformada-discreta-de-fourier/>
25. Sancho-Caparrini, F.: Introducción al aprendizaje automático. Sevilla, España (2017). <http://www.cs.us.es/~fsancho/?e=75>
26. Godoy-Viera, Á. F.: Técnicas de aprendizaje de máquina utilizadas para la minería de texto. *Investigación Bibliotecológica Archivonomía, Bibliotecología e Información*, vol. 31, no. 71 (2017) doi: 10.22201/iibi.0187358xp.2017.71.57812
27. Mitchell, T. M.: *Machine learning*, 1st ed. McGraw-Hill/Engineering/Math (1997)
28. Moreno, A., Armengol, E., Béjar, J., Belanche, L., Cortés, U., Gavaldá, R., Gimeno, J. M., López, B., Martín, M., Sánchez, M.: *Aprendizaje automático*. Cataluña, España, Ediciones UPC (1994) <chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://upcommons.upc.edu/bitstream/handle/2099.3/36157/9788483019962.pdf>
29. Bastidos, M. X.: ¿Qué es el aprendizaje de máquina y en qué casos debería usarlo en su negocio? (2020) <https://reconoserid.com/que-es-el-aprendizaje-de-maquina-y-en-que-casos-deberia-usarlo-en-su-negocio/>
30. Nilsson, N. J.: *Introduction to Machine Learning*. Stanford University (1998)
31. Cymaticcorps, Cykit. Cymaticcorp, (2017) <https://github.com/CymatiCorp/CyKit>
32. Barrios-Arce, J. I.: La matriz de confusión y sus métricas, *Health Big Data* (2019) <https://www.juanbarrios.com/la-matriz-de-confusion-y-sus-metricas/> (2021)
33. Gallegos-Acosta, A. E., Torres-Soto, M. D., Torres-Soto, A., Ponce de León-Sentí, E. E.: Contrastación de algoritmos de aprendizaje automático para la clasificación de señales EEG. *Res. Comput. Sci.*, vol. 148, no. 8, pp. 515–525 (2021) [https://www.rcs.cic.ipn.mx/2020\\_149\\_8/Contrastacion de algoritmos de aprendizaje automatico para la clasificacion de senales EEG.pdf](https://www.rcs.cic.ipn.mx/2020_149_8/Contrastacion%20de%20algoritmos%20de%20aprendizaje%20automatico%20para%20la%20clasificacion%20de%20senales%20EEG.pdf)

