

Contrastación de algoritmos de aprendizaje automático para la clasificación de señales EEG

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

Universidad Autónoma de Aguascalientes,
México

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

Resumen. El objetivo de este artículo es presentar el ajuste de parámetros y la contrastación del desempeño de dos algoritmos de aprendizaje automático: máquinas de soporte vectorial y redes neuronales artificiales. Ambos algoritmos son aplicados a la clasificación de señales EEG con imaginación motora para discriminar la intención de abrir y cerrar la mano. Para este estudio se contó con una base de datos propia obtenida por medio del dispositivo comercial Emotiv EPOC+ de catorce señales. Por medio de un diseño de experimentos factorial y un análisis estadístico, se obtuvieron los parámetros para los cuales, ambos algoritmos presentan un mejor desempeño. Así mismo, se determinó el algoritmo más adecuado para la clasificación de las señales EEG de acuerdo con su exactitud, precisión positiva, precisión negativa y las razones de falsos positivos y negativos.

Palabras clave: Aprendizaje automático, señales electroencefalográficas, máquinas de soporte vectorial, redes neuronales.

Machine Learning Algorithms Testing for EEG Signal Classification

Abstract. The purpose of this article is to present the parameter adjustment and the performance contrasting of two machine learning algorithms: support vector machines and artificial neural networks. Both algorithms are applied to the classification of EEG signals with motor imagination to discriminate the intention to open and close the hand. For this study, an own database was obtained through the Emotiv EPOC + device with fourteen signals. By means of a factorial experiment design and a statistical analysis, the parameters for which both algorithms present a better performance were obtained. Likewise, the most suitable algorithm for the classification of EEG signals was determined according to their accuracy, positive precision, negative precision, and false positive and negative rates.

Keywords: Machine learning, electroencephalographic signals, support vector machines, artificial neuronal networks.

1. Introducción

Uno de los principales objetos de estudio que ha tenido la ciencia a lo largo de la historia es el cuerpo humano. Particularmente, el cerebro ha resultado ser uno de los órganos con mayor interés debido a la complejidad de sus funciones [1]. Gracias a este interés nacen las neurociencias, un conjunto de ramas de la ciencia (neurología, física, biología, matemáticas, filosofía, sociología, ciencias computacionales, música, etc.) enfocadas en el estudio de la organización y funciones del cerebro [2]. Las neurociencias han permitido el desarrollo de herramientas y métodos que permiten encontrar soluciones a patologías y trastornos asociados al cerebro [3].

Una de las herramientas desarrolladas es el electroencefalograma (EEG), un dispositivo capaz de registrar la actividad eléctrica del cerebro y que en la actualidad es utilizado de modo rutinario [4]. La señal registrada es compleja pues contiene la suma de la actividad de diferentes poblaciones neuronales registrando incluso, otras actividades fisiológicas como el movimiento ocular, la respiración, la actividad cardíaca, etc. [4, 5]. En consecuencia, se han desarrollado técnicas de procesamiento matemático con el objetivo de mejorar la comprensión del funcionamiento cerebral [4].

El presente artículo se enfoca en la manipulación de señales electroencefalográficas de imaginación motora por medio de algoritmos de aprendizaje automático. Se expone, por medio de un diseño de experimentos factorial, el ajuste de dos algoritmos de clasificación: las redes neuronales artificiales y las máquinas de soporte vectorial. El objetivo es encontrar los parámetros que permiten un mejor desempeño en la clasificación de señales electroencefalográficas correspondientes a imaginación motora. Las señales se enfocan en la intención de abrir y cerrar la mano derecha sin ejecutar el movimiento físicamente. Para la captura de dichas señales se utilizó el dispositivo comercial Emotiv EPCO+ de 14 nodos descrito a detalle más adelante.

2. Temas principales

Este apartado se centra en abordar conceptos importantes utilizados para la elaboración de este artículo. El primero es la imaginación motora, es decir, la planeación mental de un movimiento sin la ejecución física [6]. Más adelante, se enfoca en conceptos concernientes a las ciencias computacionales como el aprendizaje automático y los dos algoritmos utilizados: las redes neuronales y las máquinas de soporte vectorial.

2.1. Imaginación de movimiento

La imaginación motora (MI), también conocida como intención de movimiento o imágenaría motora, es un concepto relativamente nuevo que consiste en la evocación de un movimiento o gesto sin ejecutarlo físicamente [6], [7].

La práctica de la MI representa un tema de investigación para las neurociencias combinando el enfoque psicológico y neuropsicológico [8].

Hoy en día, la MI es aplicada en ámbitos deportivos y terapéuticos, especialmente en pacientes con afecciones neurológicas (i.e. accidentes cardiovasculares, lesiones en médula espinal o enfermedad de Parkinson). En la literatura se ha presentado evidencia de que la práctica de MI tiene efectos positivos al mejorar el desempeño de alguna habilidad motora [9, 10].

Al igual que el movimiento real, la intención de movimiento involucra las mismas áreas cerebrales, cuyos patrones de activación se registran en el electroencefalograma en frecuencias específicas en la región sensorial-motora de la corteza cerebral (ritmo mu entre 8 y 13 Hz; ritmo beta entre 13 y 30 Hz) [6].

2.2. Aprendizaje automático

El aprendizaje automático, o machine learning (ML), es una rama de la inteligencia artificial dedicada al desarrollo de técnicas que permitan a las computadoras generalizar comportamientos y reconocer patrones a partir de la información suministrada [11], [12]. De acuerdo con Tom Mitchell en [13], *“se dice que un programa informático aprende de un conjunto de tareas, gracias a la experiencia y a una medida de rendimiento, si su desempeño en dichas tareas mejora con la experiencia”*.

Un sistema informático clásico sólo ejecuta una misma operación una y otra vez. En cambio, un sistema ML tiene la capacidad de extraer información automáticamente de los datos que procesa, de modo que el sistema “aprende”, mejorando su desempeño en tarea para la que fue programado [14].

Un modelo de aprendizaje automático se conforma de un proceso de selección y un proceso de adaptación. Primeramente, el sistema ML selecciona las características más relevantes de un evento u objeto y las contrasta con las ya conocidas. En caso de que encuentre diferencias significativas, el sistema las adapta al modelo del evento (u objeto). Finalmente, este proceso se traduce en la mejora en la calidad de actuación del sistema [15].

En la literatura existen diversos algoritmos de aprendizaje automático e incluso, variantes derivados de los mismos [16]. En este caso, se hace uso de dos de los más usados y con mejor desempeño: las redes neuronales y las máquinas de soporte vectorial.

2.3. Redes neuronales artificiales

Las redes neuronales artificiales (RNA) son un tipo de sistema de aprendizaje automático capaz de establecer relaciones no lineales entre variables de entrada y salida [17]. De manera general, proporcionan un enfoque sólido capaz de aproximar funciones objetivo de valores reales, valores discretos y vectores [13].

El funcionamiento de las redes neuronales artificiales se basa en el funcionamiento del sistema neuronal humano, un sistema complejo, no lineal y paralelo [18, 19]. Este sistema se conforma de interconexiones entre neuronas formando un punto clave para el procesamiento del conocimiento, cuya estructura es similar a un árbol [19].

En las RNA cada neurona artificial se somete a una función de activación que es modelada por una combinación lineal de las entradas de dicha neurona. Esta función de activación da como resultado la salida de la neurona [20].

Las RNA permiten la resolución de problemas e incluso, pueden trabajar en conjunto con otros métodos [19]. Son modelos del cálculo eficientes que operan en paralelo y se especializan en tareas cognitivas como aprendizaje de patrones, clasificación o la optimización [21].

2.4. Máquinas de soporte vectorial

Las máquinas de soporte vectorial (SVM por sus siglas en inglés support vector machines) son una clase poderosa de algoritmos supervisados de clasificación y regresión [22]. Se originan de la teoría del aprendizaje estadístico cuyo propósito inicial fue la resolución de problemas de clasificación binaria. Sin embargo, se han desarrollado al punto de que pueden utilizarse en problemas de regresión, agrupamiento y multi clasificación mostrando un buen desempeño [23].

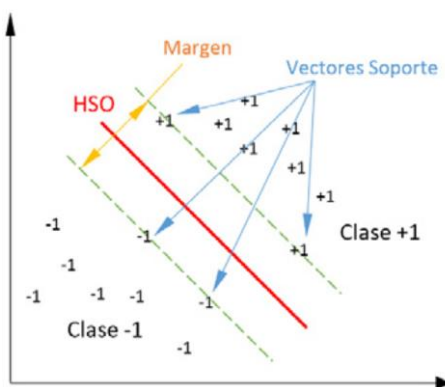


Fig. 1. Funcionamiento de una SVM [24].

En el caso más simple, las SVM determinan el hiperplano que separa los conjuntos de objetos según su clase. Este hiperplano se conoce como hiperplano de separación óptima (HSO) y se distingue de cualquier otro separador posible al maximizar el margen entre las clases [25] como se muestra en la Fig.1. Los vectores de soporte, que dan nombre al algoritmo de aprendizaje, son las características de datos que se encuentran más cercanos al HSO e influyen en su ubicación [24].

La mayoría de los casos no son problemas linealmente separables y, por lo tanto, las SVM no pueden encontrar un HSO. Sin embargo, los SVM hacen uso de métodos kernel que les permite aumentar la dimensionalidad en el mapeo de las características conocido como espacio de características. De esta manera, se puede encontrar una solución lineal en el espacio de características que, a su vez, es una solución no lineal en el espacio de entrada [23, 24].

3. Metodología

La metodología (ver Fig.2) inicia con la obtención de señales EEG orientadas específicamente a la intención de movimiento de abrir y cerrar la mano derecha.

La obtención de las señales se realizó por medio del dispositivo comercial Emotiv EPOC+ el cual, permite la captura y amplificación de ondas cerebrales generadas por acciones mentales [1]. El dispositivo posee catorce receptores (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4) distribuidos según el sistema internacional 10-20 [26]. Además, se contó la aplicación Cykit [27] de acceso libre que permitió controlar el tiempo de muestreo y registrar las observaciones en archivos de texto.

Finalmente, Cada muestra tomada tuvo una duración de 15 segundos en la cual, se solicitaba al sujeto de prueba mantener la concentración en el movimiento específico. Al final del muestreo se contó con 1283 registros conformados por 566 correspondientes a abrir la mano y 717 a cerrar la mano.

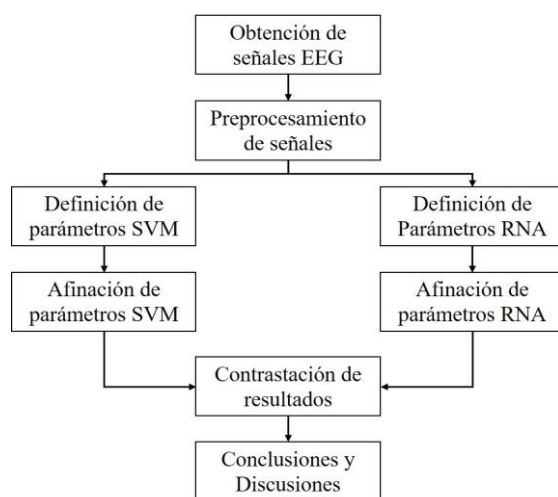


Fig. 2. Metodología.

Tabla 1. Parámetros de entrada para SVM.

Kernel	Gamma	C
rbf	1/14	1E+10
poly	0.08	1500
	0.04	200

Como segundo paso se realizó un preprocesamiento de las señales debido a la complejidad de los datos. Este preprocesamiento consistió en trasladar dichos datos a una escala común por medio de una normalización Z-score [28, 29].

Una vez de contó con los datos, se prosiguió con una definición de parámetros para un modelo de SVM y dos de RNA. Este paso consistió en buscar una serie de valores para cada parámetro con los cuales cada algoritmo de aprendizaje tuviera un buen desempeño. Los valores se basan en literatura y en pruebas empíricas realizadas a los algoritmos.

Tabla 2. Parámetros de entrada para los modelos 1 y 2 de RNA.

Modelo	Neuronas en capa oculta	Función de activación	Neuronas en capa oculta 2	Función de activación	Nº de épocas	Tamaño de lote
RNA 1 capa	75	Relu	N/A	N/A	100	10
	50	Tanh	N/A	N/A	50	5
	25					
RNA 2 capas	75	Relu	20	Relu	100	10
	50	Tanh	15	Tanh	50	5
	25					

Para el caso de las SVM, los parámetros fueron el kernel, gamma y el valor C. En el caso del kernel, se seleccionaron el rbf y el poly, de acuerdo con los valores obtenidos en [30] para la clasificación de señales EEG para detectar ojos abiertos y cerrados. Por su parte, el valor gamma (γ) define la anchura del kernel. Si su valor es demasiado grande el modelo tenderá al sobreajuste y en caso de ser muy pequeño la frontera de decisión sería muy rígida [31]. Los valores seleccionados para gamma se basan en la librería sklearn de Python cuyo valor defecto es $1/n$, siendo n el número de características que se analizan [32].

Por su parte, el valor C controla las violaciones del margen que se toleran en el proceso de ajuste [33]. Se trata de un peso de regularización que permite que se cometan errores al clasificar. Si el valor de C es muy alto, el modelo SVM permite menor número de violaciones en la clasificación [31]. En este caso, los valores de C se eligieron de manera que pudieran explorar distintos niveles de dicho valor.

En el caso de las RNA se diseñaron dos modelos como se aprecia en la Tabla 2. El primero es una RNA densa con una capa oculta y el segundo, una RNA densa de dos capas ocultas. Pues se afirma que la mayoría de los problemas no requieren de más de dos capas para proveer un buen desempeño e incluso, el uso más capas y neuronas supone un mayor costo computacional [21, 34].

Ambos modelos se componen de una capa de entrada de catorce neuronas, según el número de características a procesar; y una capa de salida con una única neurona con función de activación sigmoide que permite transformar la salida en 0 y 1, donde 0 representa una señal para abrir la mano y 1 una señal para cerrar la mano.

Para establecer los valores para los parámetros expuestos en la Tabla 2 se acudió a la realización de pruebas empíricas para analizar el comportamiento del modelo RNA con los datos de aprendizaje y validación. Para el caso del número de neuronas en la capa oculta se tomó como base la regla de Lippman la cual sostiene que problemas complejos pueden resolverse con una RNA de una capa oculta siempre y cuando, se incluya al menos tres veces el número de nodos de entrada [21]. Sin embargo, existen diversas topologías de RNA y queda a consideración el número de neuronas en cada capa oculta [35].

Para el segundo modelo de RNA se incluye una segunda capa oculta con un número de neuronas menor al de la primera capa oculta. De esta manera, se ajusta a la regla de la pirámide geométrica donde se establece que el número de neuronas ha de ser menor al número de entradas, en este caso la capa oculta anterior [21, 34].

Al igual que en el modelo 1 de RNA, para el modelo 2 se realizaron ejecuciones empíricas para conocer su desempeño y saber qué valores se ajustan mejor a la clasificación esperada.

De acuerdo con la metodología de la Fig. 3, el siguiente paso es la afinación de parámetros para ambos algoritmos de aprendizaje. Para ello, se realizó un diseño de experimentos factorial para cada algoritmo de aprendizaje en el que se ejecutó cada configuración de parámetros y se replicaron treinta veces para formar grupos de experimentos. A partir de estos grupos de experimentos se realizaron pruebas estadísticas para determinar la existencia de diferencias entre los grupos y encontrar las configuraciones que permiten un mejor desempeño, es decir, que maximice la exactitud, la precisión positiva y negativa; y a su vez, minimice las razones de falsos positivos y negativos.

Una vez terminada la afinación de parámetros, se realizó una contrastación de resultados. Este paso en la metodología consistió en determinar la existencia de diferencias significativas entre los mejores grupos de cada algoritmo y así conocer aquel que resulta más adecuado en la clasificación de señales EEG con imaginación motora.

4. Resultados

Como se mencionó anteriormente, cada configuración de parámetros en los modelos SVM y RNA se replicó en un total de 30 ocasiones independientes cuyas salidas fueron las métricas de la matriz de confusión de cada réplica: la exactitud, la precisión positiva, la precisión negativa y las razones de falsos positivos y negativos.

Para las RNA los modelos de una y dos capas ocultas se analizaron en conjunto. El análisis comenzó con una prueba Shapiro Wilk con la que se encontró que las variables de salida no siguen una distribución normal, por lo tanto, se optó por estadística no paramétrica. Dado este resultado, se realizó una prueba Kruskal-Wallis con la que se descubrió la existencia de diferencia significativa entre los grupos de réplicas. Así pues, se seleccionaron empíricamente cuatro grupos de cada modelo RNA de acuerdo con su desempeño, es decir, los grupos que maximizan su exactitud y precisión (positiva y negativa) y minimizan la razón de falsos positivos y falsos negativos.

Dada una nueva prueba de Kruskal-Wallis los grupos seleccionados resultan ser equiparables estadísticamente. Por lo tanto, para el RNA de una capa oculta se seleccionó la configuración de 75 neuronas en su capa oculta, la función de activación relu, 100 épocas y un tamaño de batch de 5. Este modelo fue seleccionado pues maximiza la exactitud con un 95.71% y una precisión positiva y negativa de 95.6% y 95.88%, respectivamente. A su vez, minimiza las razones de falsos positivos y negativos con 4.11% y 4.39%, respectivamente (ver Tabla 3).

En cuanto a los modelos de RNA con dos capas se seleccionó la configuración con 75 neuronas y función de activación relu en la primera capa, 15 neuronas y activación relu en la segunda capa, 100 épocas y un batch de 5. Este modelo se distingue de los otros modelos de 2 capas pues maximiza la exactitud con un 95.81% y la precisión positiva con un 96.07%. A su vez, minimiza únicamente la razón de falsos negativos con un 3.92%.

Tabla 3. Mejores modelos en SVM y RNA.

Modelo	Configuración	E.	P (+)	P (-)	R. F (+)	R. F (-)
RNA 1 capa	C1:75, A: relu, Epec: 100, Batch: 5	95.71	95.60	95.88	4.11	4.39
RNA 2 capas	C1: 75, A: relu, C2: 15, A: relu, Epec: 100, Batch: 5	95.81	96.07	95.51	4.48	3.92
SVM	Kernel: rbf, Gama: 0.04, C: 200	93.00	93.06	92.93	7.06	6.93

El mejor modelo una capa y el mejor de dos capas se realizó una prueba U-Mann Whitney resultando en que son equiparables estadísticamente. Sin embargo, se puede observar en la Tabla 3, que el modelo de dos capas es empíricamente superior, aunque requiere un mayor costo computacional. Por lo tanto, se eligen el modelo de una capa al ser un modelo con menor complejidad, menor costo computacional e, incluso, menor tiempo de ejecución observado.

En cuanto a los grupos de experimentos de SVM, el proceso fue similar. Una prueba de Shapiro Wilk determinó que los grupos no siguen una distribución normal y, por lo tanto, se requirió de estadística no paramétrica.

De acuerdo con una prueba Kruskal-Wallis se determinó la existencia de diferencias significativas entre los grupos de experimentos. Dada la diferencia entre los grupos, se seleccionaron de forma empírica los cuatro mejores según la maximización de la exactitud y las precisión positiva y negativa, así como la minimización de las razones de falsos positivos y negativos.

Los cuatro grupos se sometieron a una nueva prueba de Kruskal-Wallis que resultó en la existencia de diferencia significativa respecto a las cinco variables de salida. Entonces se decide optar por contrastar dos grupos:

- Grupo 8 con kernel: rbf, gamma: 0.04, c: 200, exactitud de 93%, precisión positiva de 93.06%, precisión negativa de 92.93%, razón de falsos positivos de 7.06%, razón de falsos negativos de 6.93%
- Grupo 18 con kernel: poly, gamma: 0.04, c: 200, exactitud de 77.66%, precisión positiva de 64.48%, precisión negativa de 94.40%, razón de falsos positivos de 5.59%, razón de falsos negativos de 35.51%

El grupo 8 maximiza la exactitud, la precisión positiva y minimiza la razón de falsos negativos. En cambio, el grupo 18 maximiza la precisión negativa y minimiza la razón de falsos positivos. Ambos grupos se contrastaron por medio de una prueba U-Mann Whitney resultado en que son grupos estadísticamente distintos. Por esta razón, se opta por el grupo 8 (ver Tabla 3) al ser superior en tres de las cinco variables de salida.

Finalmente, se realizó una nueva contrastación entre los modelos SVM y RNA por medio de sus grupos elegidos como mejores de acuerdo con el análisis estadístico aplicado. En este caso, se seleccionó el modelo de una capa oculta de RNA y el modelo de SVM descritos en la Tabla 3.

Por medio de una prueba U-Mann Whitney se determinó la existencia de diferencia significativa entre ambos grupos.

Sin embargo, y como se puede observar en la Tabla 3, el modelo RNA de una capa oculta maximiza la exactitud y la precisión tanto positiva y negativa al tiempo que minimiza la razón de falsos positivos y falsos negativos. Es por ello por lo que puede considerarse como la mejor opción para clasificación de señales EEG.

5. Conclusiones y trabajo a futuro

En conclusión, se tiene que los algoritmos de aprendizaje automático, tanto las máquinas de soporte vectorial como las redes neuronales artificiales, son herramientas muy robustas que pueden adaptarse a distintos problemas como la clasificación de señales EEG. Sin embargo, la tarea de ajustar los parámetros de los algoritmos es crucial para obtener un buen desempeño y uso adecuado de recursos computacionales.

Esto se debe a que es posible obtener un modelo de clasificación con muy buen desempeño y que, a su vez, sea demasiado complejo y sea necesario un reajuste de parámetros u optar por un modelo distinto. Por ejemplo, los modelos de RNA con una y dos capas, descritos en la Tabla 3, donde ambos modelos obtuvieron un buen desempeño, sin embargo, se puede observar que el modelo con dos capas ocultas es superior en sus variables de salida. No obstante, se trata de un modelo con mayor complejidad y mayor costo computacional. Es por ello, que se puede optar por un modelo más sencillo cuyo desempeño puede ser mínimamente inferior, pero con mejor uso de recursos.

La manipulación de señales EEG por medio de la inteligencia artificial provee grandes avances en la detección de enfermedades relacionadas al funcionamiento cerebral. Así como la creación de nuevas herramientas que promueven la inclusión de personas con discapacidades físicas, permitiéndoles manipular dispositivos por medio de la traducción de las señales en comandos de control.

Como trabajo a futuro se tiene propuesto realizar pruebas similares tomando en cuenta el tiempo como factor de decisión para seleccionar el modelo más adecuado para la clasificación de señales electroencefalográficas con imaginación motora.

Referencias

1. Chávez-Saenz, V., Torres-Ramírez, D., Herrera-Ogaz, J., Hernández-Rodríguez, A.: Adquisición y análisis de señales electroencefalográficas utilizando el dispositivo Emotiv EPOC+. 3(7), ECOFARN, pp. 107–118 (2016)
2. Ibanez, A., García, A.: Que son las Neurociencias. Ediciones Paidós (2015)
3. Espinosa, L.: Electroencefalografía inalámbrica: una mirada actual y propuesta de sistema portátil. Universidad Técnica Federico Santa María (2016)
4. Urrestarazu, E., Iriarte, J.: Mathematical analyses in the study of electroencephalographic signals. *Rev. Neurol.*, 41(5), pp. 423–434 (2005)
5. 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. *Rev. Mex. Ing. biomédica*, 34(1), pp. 23–39 (2013)
6. Carino-Escobar, R., Cantillo-Negrete, J., Gutiérrez-Martínez, J., Vázquez, R.A.: Decodificación de imaginación motora en la señal de electroencefalograma mediante mapas auto-organizados. *Rev. del Cent. Investig. la Univ. La Salle*, 12(45), pp. 107–125 (2016)

7. 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.*, 66(5), pp. 137–146 (2018)
8. Di-Rienzo, F., Debarnot, U., Daligault, S., Saruco, E., Delpuech, C., Doyon, J., Collet, C., Guillot, A.: Online and offline performance gains following motor imagery practice: a comprehensive review of behavioral and neuroimaging studies. *Front. Hum. Neurosci.*, 10, pp. 315 (2016)
9. Dickstein, R., Deutsch, J.E.: Motor imagery in physical therapist practice. *Phys. Ther.*, 87(7), pp. 942–953 (2007)
10. Marengo, S.: Tipos de imaginación motora y procesamiento predictivo. *Poiésis*, 1, pp. 58–71 (2018)
11. Sancho-Caparrini, F.: Introducción al aprendizaje automático. <http://www.cs.us.es/~fsancho/?e=75> (2019)
12. Soto-Valero, C.: Aplicación de métodos de aprendizaje automático en el análisis y la predicción de resultados deportivos. Retos: nuevas tendencias en educación física, deporte y recreación, 34, pp. 377–382 (2018)
13. Mitchell, T.M.: *Machine Learning*. McGraw-Hill (1997)
14. González-García, C.: En qué consiste el aprendizaje automático (machine learning) y qué está aportando a la Neurociencia Cognitiva. *Cienc. Cogn.*, 12(2), pp. 48–50 (2018)
15. Moreno, A.: *Aprendizaje automático*. Universitat Politècnica de Catalunya, Edicions UPC (1994)
16. Cerón, J.P.: 8 algoritmos de aprendizaje automático data mining más usados. <https://www.arame.com.mx/blog/8-algoritmos-aprendizaje-automatado-data-mining-mas-usados-arama-blog/> (2020)
17. Villada, F., Muñoz, N., García-Quintero, E.: Redes neuronales artificiales aplicadas a la predicción del precio del oro. *Informacion Tecnologica*, (27)5, pp. 143–150 (2016)
18. Izaurieta, F., Saavedra, C.: *Redes neuronales artificiales*. Concepción (2000)
19. Rivas-Asanza, W., Mazon-Olivo, B., Mejia, F.: Capítulo 1: Generalidades de las redes neuronales artificiales. In *Redes neuronales artificiales aplicadas al reconocimiento de patrones*, Universidad Técnica de Machala, pp. 11–35 (2018)
20. Pava-Chipol, N.D., Hernández-Gomez, L.H., Beltran-Fernandez, J.A., Pava-Chipol, J.F., Moreno-Garibaldi, P.: Implementación de las redes neuronales artificiales para seleccionar los componentes de una prótesis modular transfemoral. *DYNA New Technol.*, 4(1) (2017)
21. Lévy-Magin, J.P., Flórez López, R., Fernández Fernández, J.M.: *Las Redes Neuronales Artificiales. Fundamentos teóricos y aplicaciones prácticas*. (2008)
22. VanderPlas, J.: *Python Data Science Handbook*. O'Reilly (2017)
23. Carmona, E.: *Tutorial sobre Máquinas de Vectores Soporte (SVM)* (2016)
24. González, R., Barrientos, A., Toapanta, M., Del Cerro, J.: Aplicación de las máquinas de soporte vectorial (SVM) al diagnóstico clínico de la enfermedad de párkinson y el temblor esencial. *RIAI - Rev. Iberoam. Autom. e Inform. Ind.*, 14(4), pp. 394–405 (2017)
25. Betancourt, G.: Las máquinas de soporte vectorial (SVMs). *Sci. Tech.*, 27 (2005)
26. Soria-Morillo, L., Alvarez-Garcia, J., Gonzalez-Abril, L., Ortega, J.: Discrete classification technique applied to TV advertisements liking recognition system based on low-cost EEG headsets. *Biomed. Eng. Online*, 15 (2016)
27. Cymaticcorp: *Cykit Cymaticcorp*. <https://github.com/CymatiCorp/CyKit> (2017)
28. 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*, 39(22), pp. 36–48 (2018)
29. Carlos-Cubero, J., Berzal, F.: *Introducción a SPSS. Sistemas Inteligentes de Gestión*. <https://elvex.ugr.es/decsai/intelligent/workbook/D0 SPSS.pdf> (2020)
30. Santa-Cruz, O., Del Mar-Ramírez, L., Trujillo-Romero, F.: *Técnicas de aprendizaje*

- automático aplicadas a electroencefalogramas. *Research in Computer Science*, 113. Instituto Politécnico Nacional, pp. 53–65 (2016)
31. Salamanca-Polo, L.: Generación de conjuntos de máquinas de soporte vectorial mediante técnicas de remuestreo e inyección de ruido en las etiquetas de clase. Universidad Autónoma de Madrid (2017)
 32. Scikit-learn developers: Sklearn.svm.SVC, Scikit learn. <https://scikit-learn.org/stable/modules/generated/sklearn.svm.SVC.html> (2020)
 33. Rodrigo, J.A.: Máquinas de Vector Soporte (Support Vector Machines, SVMs), https://www.cienciadatos.net/documentos/34_maquinas_de_vector_soporte_support_vector_machines (2020)
 34. Paz-Villaseca, D.I.: Herramientas deep learning para predictive analytics. Universidad de Concepción (2017)
 35. Torres-López, S., Lazara, M., Cuza, A., Piñero-Perez, P.Y., Piedra-Diéguez, L.A.: Red neuronal multicapa para la evaluación de competencias laborales Multilayer neural network for assessment of labor competences. *Revista Cuba Ciencias Informáticas*, 10 (2016)