



**UNIVERSIDAD AUTÓNOMA
DE AGUASCALIENTES**

**UNIVERSIDAD AUTÓNOMA DE AGUASCALIENTES
CENTRO DE CIENCIAS BÁSICAS
DEPARTAMENTO DE CIENCIAS DE LA COMPUTACIÓN**

**Obtención y Manipulación de Señales Electroencefalográficas por Medio de
Metaheurísticas Híbridas**

TESIS QUE PRESENTA

Alexis Edmundo Gallegos Acosta

**PARA OPTAR POR EL GRADO DE
DOCTORADO EN CIENCIAS APLICADAS Y TECNOLOGÍA**

LGAC

INTELIGENCIA ARTIFICIAL Y MODELACIÓN ESTADÍSTICA

TUTOR

María Dolores Torres Soto

COTUTOR

Aurora Torres Soto

COMITÉ TUTORAL

Eunice Esther Ponce de León Sentí

FECHA

Aguascalientes, Ags., Noviembre 2022



Obtención y Manipulación de Señales Electroencefalográficas por Medio de Metaheurísticas Híbridas

M. C. C. Alexis Edmundo Gallegos Acosta

Universidad Autónoma de Aguascalientes
Centro de Ciencias Básicas
Departamento de Ciencias de la Computación

TUTOR:

Dra. María Dolores Torres Soto
Universidad Autónoma de Aguascalientes –México
Centro de Ciencias Básicas
Departamento de Sistemas de Información

COTUTOR:

Dra. Aurora Torres Soto
Universidad Autónoma de Aguascalientes –México
Centro de Ciencias Básicas
Departamento de Ciencias de la Computación

COMITÉ TUTORAL:

Dra. Eunice Esther Ponce de León Sentí
Universidad Autónoma de Aguascalientes –México
Centro de Ciencias Básicas
Departamento de Ciencias de la Computación

CARTA DE VOTO APROBATORIO
INDIVIDUAL

Mtro. En C. Jorge Martín Alférez Chávez
DECANO DEL CENTRO DE CIENCIAS BÁSICAS

PRESENTE

Por medio del presente como *TUTORA* designada del estudiante *ALEXIS EDMUNDO GALLEGOS ACOSTA* con ID *139484* quien realizó la tesis titulado: *OBTENCIÓN Y MANIPULACIÓN DE SEÑALES ELECTROENCEFALOGRÁFICAS POR MEDIO DE METAHEURÍSTICAS HÍBRIDAS*, un trabajo propio, innovador, relevante e inédito y con fundamento en el Artículo 175, Apartado II del Reglamento General de Docencia doy mi consentimiento de que la versión final del documento ha sido revisada y las correcciones se han incorporado apropiadamente, por lo que me permito emitir el **VOTO APROBATORIO**, para que *él* pueda proceder a imprimir, así como continuar con el procedimiento administrativo para la obtención del grado.

Pongo lo anterior a su digna consideración y sin otro particular por el momento, me permito enviarle un cordial saludo.

ATENTAMENTE
"Se Lumen Proferre"
Aguascalientes, Ags., a *14 de noviembre de 2022.*



Dra. María Dolores Torres Soto
Tutora

c.c.p.- Interesado
c.c.p.- Secretaría Técnica del Programa de Posgrado

Elaborado por: Depto. Apoyo al Posgrado.
Revisado por: Depto. Control Escolar/Depto. Gestión de Calidad.
Aprobado por: Depto. Control Escolar/ Depto. Apoyo al Posgrado.

Código: DO-SEE-FO-07
Actualización: 01
Emisión: 17/05/19

CARTA DE VOTO APROBATORIO
INDIVIDUAL

Mtro. En C. Jorge Martín Alférez Chávez
DECANO DEL CENTRO DE CIENCIAS BÁSICAS

PRESENTE

Por medio del presente como *COTUTORA* designada del estudiante *ALEXIS EDMUNDO GALLEGOS ACOSTA* con ID *139484* quien realizó la tesis titulada: *OBTENCIÓN Y MANIPULACIÓN DE SEÑALES ELECTROENCEFALOGRÁFICAS POR MEDIO DE METAHEURÍSTICAS HÍBRIDAS*, un trabajo propio, innovador, relevante e inédito y con fundamento en el Artículo 175, Apartado II del Reglamento General de Docencia doy mi consentimiento de que la versión final del documento ha sido revisada y las correcciones se han incorporado apropiadamente, por lo que me permito emitir el **VOTO APROBATORIO**, para que *él* pueda proceder a imprimir, así como continuar con el procedimiento administrativo para la obtención del grado.

Pongo lo anterior a su digna consideración y sin otro particular por el momento, me permito enviarle un cordial saludo.

ATENTAMENTE
"Se Lumen Proferre"
Aguascalientes, Ags., a *14 de noviembre de 2022.*


Dra. Aurora Torres Soto
Cotutora

c.c.p.- Interesado
c.c.p.- Secretaría Técnica del Programa de Posgrado

Elaborado por: Depto. Apoyo al Posgrado.
Revisado por: Depto. Control Escolar/Depto. Gestión de Calidad.
Aprobado por: Depto. Control Escolar/ Depto. Apoyo al Posgrado.

Código: DO-SEE-FO-07
Actualización: 01
Emisión: 17/05/19



Mtro. En C. Jorge Martín Alférez Chávez
DECANO (A) DEL CENTRO DE CIENCIAS BÁSICAS

PRESENTE

Por medio del presente como **ASESORA** designado del estudiante **ALEXIS EDMUNDO GALLEGOS ACOSTA** con ID **139484** quien realizó la tesis titulada: **OBTENCIÓN Y MANIPULACIÓN DE SEÑALES ELECTROENCEFALOGRÁFICAS POR MEDIO DE METAHEURÍSTICAS HÍBRIDAS**, un trabajo propio, innovador, relevante e inédito y con fundamento en el Artículo 175, Apartado II del Reglamento General de Docencia doy mi consentimiento de que la versión final del documento ha sido revisada y las correcciones se han incorporado apropiadamente, por lo que me permito emitir el **VOTO APROBATORIO**, para que **él** pueda proceder a imprimirla y así como continuar con el procedimiento administrativo para la obtención del grado.

Pongo lo anterior a su digna consideración y sin otro particular por el momento, me permito enviarle un cordial saludo.

ATENTAMENTE
"Se Lumen Proferre"

Aguascalientes, Ags., a 14 de noviembre de 2022.

A handwritten signature in blue ink, appearing to read 'Eunice Ponce de León Senti'.

Dra. Eunice Esther Ponce de León Senti
Asesora de tesis

El nombre completo que aparece en el Voto Aprobatorio debe coincidir con el que aparece en el documento pdf. No se puede abreviar, ni omitir nombres.

c.c.p.- Interesado
c.c.p.- Secretaría Técnica del Programa de Posgrado

Elaborado por: Depto. Apoyo al Posgrado.
Revisado por: Depto. Control Escolar/Depto. Gestión de Calidad.
Aprobado por: Depto. Control Escolar/ Depto. Apoyo al Posgrado.

Código: DO-SEE-FO-07
Actualización: 01
Emisión: 17/05/19



DICTAMEN DE LIBERACIÓN ACADÉMICA PARA INICIAR LOS TRÁMITES DEL EXAMEN DE GRADO



Fecha de dictaminación dd/mm/aaaa: 18/11/2022

NOMBRE: Alexis Edmundo Gallegos Acosta **ID** 139484

PROGRAMA: Doctorado en Ciencias Aplicadas y Tecnología **LGAC (del posgrado):** Inteligencia Artificial y Modelación Estadística

TIPO DE TRABAJO: () Tesis () Trabajo Práctico

TÍTULO: Obtención y Manipulación de Señales Electroencefalográficas por Medio de Metaheurísticas Híbridas

IMPACTO SOCIAL (señalar el impacto logrado): Se desarrolló y se implementó una metodología de clasificación de señales electroencefalográficas con intención de movimiento basada en heurísticas y metaheurísticas; utilizadas para la rehabilitación de personas con alguna discapacidad motora.

INDICAR	SI	NO	N.A. (NO APLICA)	SEGÚN CORRESPONDA:
<i>Elementos para la revisión académica del trabajo de tesis o trabajo práctico:</i>				
SI				El trabajo es congruente con las LGAC del programa de posgrado
SI				La problemática fue abordada desde un enfoque multidisciplinario
SI				Existe coherencia, continuidad y orden lógico del tema central con cada apartado
SI				Los resultados del trabajo dan respuesta a las preguntas de investigación o a la problemática que aborda
SI				Los resultados presentados en el trabajo son de gran relevancia científica, tecnológica o profesional según el área
SI				El trabajo demuestra más de una aportación original al conocimiento de su área
SI				Las aportaciones responden a los problemas prioritarios del país
NO				Generó transferencia del conocimiento o tecnológica
SI				Cumple con la ética para la investigación (reporte de la herramienta antiplagio)
<i>El egresado cumple con lo siguiente:</i>				
SI				Cumple con lo señalado por el Reglamento General de Docencia
SI				Cumple con los requisitos señalados en el plan de estudios (créditos curriculares, optativos, actividades complementarias, estancia, predoctoral, etc)
SI				Cuenta con los votos aprobatorios del comité tutorial, en caso de los posgrados profesionales si tiene solo tutor podrá liberar solo el tutor
N.A.				Cuenta con la carta de satisfacción del Usuario
SI				Coincide con el título y objetivo registrado
SI				Tiene congruencia con cuerpos académicos
SI				Tiene el CVU del Conacyt actualizado
SI				Tiene el artículo aceptado o publicado y cumple con los requisitos institucionales (en caso que proceda)
<i>En caso de Tesis por artículos científicos publicados</i>				
SI				Aceptación o Publicación de los artículos según el nivel del programa
SI				El estudiante es el primer autor
NO				El autor de correspondencia es el Tutor del Núcleo Académico Básico
SI				En los artículos se ven reflejados los objetivos de la tesis, ya que son producto de este trabajo de investigación.
SI				Los artículos integran los capítulos de la tesis y se presentan en el idioma en que fueron publicados
SI				La aceptación o publicación de los artículos en revistas indexadas de alto impacto

Con base a estos criterios, se autoriza se continúen con los trámites de titulación y programación del examen de grado: Sí No

FIRMAS

Elaboró:
 * NOMBRE Y FIRMA DEL CONSEJERO SEGÚN LA LGAC DE ADSCRIPCIÓN: Dr. Jaime Martínez Arteaga
 NOMBRE Y FIRMA DEL SECRETARIO TÉCNICO: Dr. Angel Eduardo Méndez Zavala
* En caso de conflicto de intereses, firmará un revisor miembro del NAB de la LGAC correspondiente distinto al tutor o miembro del comité tutorial, asignado por el Decano
Revisó:
 NOMBRE Y FIRMA DEL SECRETARIO DE INVESTIGACIÓN Y POSGRADO: Dr. Juan Jauregui Rincón
Autorizó:
 NOMBRE Y FIRMA DEL DECANO: Mtro. Jorge Martín Alférez Chávez

Nota: procede el trámite para el Depto. de Apoyo al Posgrado
 En cumplimiento con el Art. 105C del Reglamento General de Docencia que a la letra señala entre las funciones del Consejo Académico: ... Cuidar la eficiencia terminal del programa de posgrado y el Art. 105F las funciones del Secretario Técnico, llevar el seguimiento de los alumnos.

	INTEGRACION DEL OPERADOR DE ALTERACIÓN A METAHEURÍSTICAS EVOLUTIVAS PARA LA APLICACIÓN DE LA TEORÍA DE TESTORES EN PATOLOGÍAS MÉDICAS	CIENCIA DE LOS ORDENADORES
	ARTÍCULO DE INVESTIGACION Alexis Edmundo Gallegos-Acosta, María Dolores Torres-Soto, Francisco Javier Álvarez-Rodríguez, Aurora Torres-Soto	Inteligencia Artificial

INTEGRACIÓN DEL OPERADOR DE ALTERACIÓN A METAHEURÍSTICAS EVOLUTIVAS PARA LA APLICACIÓN DE LA TEORÍA DE TESTORES EN PATOLOGÍAS MÉDICAS

Alexis Edmundo Gallegos-Acosta, Dolores Torres-Soto, Francisco Álvarez-Rodríguez y Aurora Torres-Soto

Universidad Autónoma de Aguascalientes, UAA. Dpto. de Ciencias de la Computación. Av. Universidad #940 –20131, Ciudad Universitaria, Aguascalientes, Ags., México. Tfno. +52 (449) 910 7400 ext. 358 alexisEdm@gmail.com

Recibido: 17/Ene/2019–Revisando: 22/Ene/2019–Aceptado: 6/May/2019-DOI: <http://dx.doi.org/10.6036/NT9093>

TO CITE THIS ARTICLE:

GALLEGOS-ACOSTA, Alexis Edmundo, TORRES-SOTO, María Dolores, ALVAREZ-RODRIGUEZ, Francisco Javier et al. INTEGRATION OF THE ALTERATION OPERATOR TO EVOLUTIONARY METAHEURISTICS FOR THE APPLICATION OF THE TESTOR THEORY IN MEDICAL PATHOLOGIES. DYNA New Technologies, Enero-Diciembre 2019, vol. 6, no. 1, p.[12 p.]. DOI: <http://dx.doi.org/10.6036/NT9093>

INTEGRATION OF THE ALTERATION OPERATOR TO EVOLUTIONARY METAHEURISTICS FOR THE APPLICATION OF THE TESTOR THEORY IN MEDICAL PATHOLOGIES

<p>ABSTRACT:</p> <p>This paper presents the design and integration of the “alteration operator” to evolutive metaheuristics (GA and EDA). The aim is searching typical testors for feature selection in medical data. This operator avoids the aleatory search working as a support of the exploration of the solutions space. The hybrid metaheuristics found the typical testors associated to the analyzed data which are irreducible subsets that allow to classify new instances. The informational weight was used to know the impact of each feature in the classification process. Finally, the tuning and contrasting of metaheuristics is presented in order to find the best parameter values that improve their performance and determine the most appropriate metaheuristics for each pathology.</p> <p>Keywords: alteration operator, genetic algorithm, estimation of distribution algorithm, testor theory, feature subset selection.</p>	<p>RESUMEN:</p> <p>El presente artículo presenta el diseño e integración del “operador de alteración” a metaheurísticas evolutivas (AG y EDA), con el objetivo es la búsqueda de testores típicos para la selección de características a datos médicos. Este operador funciona como soporte en la exploración del espacio de soluciones evitando la búsqueda aleatoria. Las metaheurísticas híbridadas encuentran los testores típicos asociados a los datos analizados que son subconjuntos irreducibles capaces de realizar clasificación. Para interpretar los testores típicos encontrados se calculó el peso informacional para determinar el impacto de cada característica en el proceso de clasificación. Finalmente, se presenta la afinación y contrastación de metaheurísticas para encontrar los mejores valores de parámetros que mejoran su desempeño y determinar la metaheurística más adecuada para cada patología.</p> <p>Palabras clave: operador de alteración, algoritmo genético, algoritmo de estimación de la distribución, teoría de testores, selección de subconjuntos de características.</p>
---	---

1.- INTRODUCCION

El aprendizaje automático se asocia al procesamiento de grandes volúmenes de datos pues, gracias a la digitalización de la información, las bases de datos son más robustas y complejas [1, 2]. Esto puede observarse en redes sociales, atención médica, bioinformática y educación en línea [2]. Así, la selección de subconjuntos de características (SSC) ha tomado gran importancia en aprendizaje automático, reconocimiento de patrones y minería de datos pues permite distinguir eficientemente variables/características relevantes de las irrelevantes o redundantes. En consecuencia, se reduce la dimensionalidad obteniendo modelos de análisis (clasificación, agrupamiento, regresión, etc.) más sencillos y comprensibles mejorando su desempeño y disminuyendo requerimientos computacionales [3-5].

Manipulación de metaheurísticas para la búsqueda de testores típicos

Manipulation of metaheuristics for the search of typical testers

■ ■ ■ ■
 Alexis-Edmundo Gallegos-Acosta, Dolores Torres-Soto, Francisco Álvarez-Rodríguez y Aurora Torres-Soto
 Universidad Autónoma de Aguascalientes (México)

DOI: <http://dx.doi.org/10.6036/9375>

Una de las tareas del reconocimiento de patrones es la selección de subconjuntos de características (SSC), que permite identificar características que aporten información relevante. Existen diferentes enfoques para aplicar SSC siendo el enfoque lógico-combinatorio por medio de la teoría de testores, una herramienta muy utilizada [1]. Un testor es un subconjunto de características capaz de distinguir objetos de distintas clases. Los testores en su mínima expresión son conocidos como testores típicos (TT). Encontrarlos permite distinguir variables relevantes de las redundantes o irrelevantes, de manera que los modelos de análisis de datos se vuelven más sencillos y comprensibles, mejorando su desempeño y disminuyendo requerimientos computacionales.

El inconveniente principal del cálculo de los TT es su complejidad exponencial respecto de la cantidad de características [2]. Por esta razón, se han creado diferentes alternativas como la hibridación de metaheurísticas. En este documento se expone el "operador de alteración" y su inclusión en metaheurísticas para la búsqueda de TT.

El "operador de alteración" (OA) es un nuevo operador propuesto en [3], diseñado para enriquecer la búsqueda de TT, encontrándolos inmersos en las soluciones generadas por las metaheurísticas. Su importancia radica en evitar que la metaheurística se transforme en una búsqueda aleatoria sin encontrar los TT asociados al problema analizado.

El OA fue diseñado para incorporarse a metaheurísticas poblacionales evolutivas como el EDA.

El modelo comienza con la población inicial (ver Fig.1), evaluada por medio de la matriz básica (matriz con la información básica de las diferencias entre clases de objetos. Revisar [3] y [2]). Posteriormente,

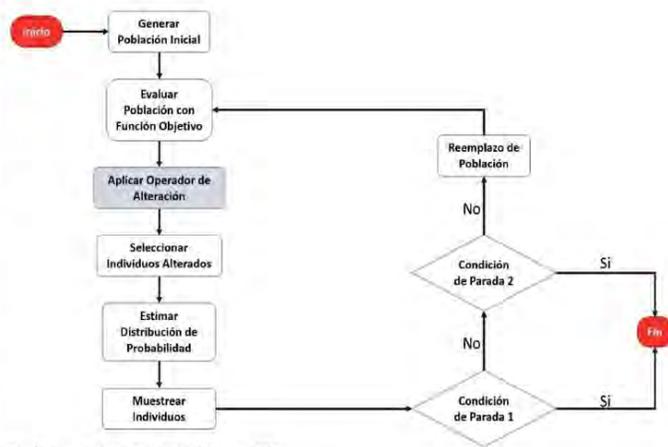


Fig. 1: Ejemplo de inclusión del OA en un EDA

la población es alterada por el OA analizando la vecindad de las soluciones para extraer mejores, eliminando o agregando características a los individuos/conjuntos. Las soluciones mejoradas con el OA se denominan "sobrevivientes". A partir de ellas, se seleccionan sobrevivientes únicos para formar parte de la nueva población. La nueva población se completa por medio de los operadores habituales de la metaheurística subyacente, manteniendo diversidad en la población. Finalmente, se comprueban las condiciones de paro para continuar o detener el algoritmo.

El OA se integró a un algoritmo de estimación de distribuciones y un algoritmo genético, demostrando su capacidad para evitar búsquedas aleatorias. Ambos casos se probaron en células de cáncer [3], donde 8 de 10 características resultaron imprescindibles para clasificar células benignas y malignas. Sin embargo, es posible desconocer una de las características restantes, pero no ambas. Además, se hicieron pruebas en hemofilia con 11 características resultando una imprescindible y se descartó otra, debido a su bajo peso informativo y cuyo dato podía conocerse mediante de otra con un mayor peso.

La SSC es una herramienta que permite trabajar con las variables/características

más relevantes distinguiéndose eficientemente de aquellas irrelevantes o redundantes. De esta manera, tareas como decidir, clasificar, agrupar o aplicar regresión, se vuelven más sencillas y comprensibles, con mejor desempeño y menores requerimientos computacionales. Por su parte, el OA beneficia ampliamente el desempeño de las metaheurísticas en la búsqueda de TT permitiéndoles una convergencia más adecuada respecto de la concepción pura de la metaheurística.

REFERENCIAS

- [1] V. I. González Guevara, S. Godoy Calderon, E. Alba Cabrera, and J. Ibarra Fiallo, "A Mixed Learning Strategy for Finding Typical Testors in Large Datasets," in Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications, 1st ed., Montevideo, Uruguay: Springer, 2015, pp. 716–724.
- [2] J. Ruiz Shucloper, E. Alba Cabrera, and M. Lazo Cortés, "Introducción a la Teoría de Testores," Departamento de Ingeniería Eléctrica, CINVESTAV-IPN, p. 197, 1995.
- [3] A. E. Gallegos Acosta, M. D. TORRES SOTO, F. J. ALVAREZ RODRIGUEZ, and A. TORRES SOTO, "INTEGRACIÓN DEL OPERADOR DE ALTERACIÓN A METAHEURÍSTICAS EVOLUTIVAS PARA LA APLICACIÓN DE LA TEORÍA DE TESTORES EN PATOLOGÍAS MÉDICAS," DYNA NEW Technologies, vol. 6, no. 1, [12 p.] 2019 DOI: <https://dx.doi.org/10.6036/NT9093>

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.

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 Senti

Benemérita Universidad Autónoma de Aguascalientes,
Aguascalientes, Ags., 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

14/9/22, 11:38

Gmail - COMIA 2021 notificación del artículo 126



Alexis Gallegos <alexisedm@gmail.com>

COMIA 2021 notificación del artículo 126

3 mensajes

COMIA 2021 <comia2021@easychair.org>
Para: Alexis Gallegos <alexisedm@gmail.com>

12 de mayo de 2021, 0:03

Estimada(o) Alexis Gallegos,

Nos complace informarle que su artículo:
Tratamiento de Señales Electroencefalográficas de Imaginación Motora con Fines de Clasificación
ha sido ACEPTADO.

Su artículo será publicado como número especial de la revista "Research in Computing Science", de publicación periódica con ISSN, indexada en LatIndex y DBLP.

Los artículos no deberán exceder de 14 páginas y el artículo final deberá ser presentado en el formato de las plantillas para Word o Latex disponibles en la página web www.smia.mx/comia/2021.

El conjunto de revisiones de su artículo está al final de este mensaje. Por favor, tome en cuenta las recomendaciones recibidas para preparar la versión final, misma que deberá ser enviada para el 19 de mayo de 2021.

En breve les compartiremos la página para hacemos llegar su versión final, las credenciales de acceso, y otra información complementaria.

Posteriormente recibirá información sobre su presentación en el COMIA 2021.

Atentamente,

Presidentes del Comité de Programa del COMIA 2021

SUBMISSION: 126
TITLE: Tratamiento de Señales Electroencefalográficas de Imaginación Motora con Fines de Clasificación

----- REVIEW 1 -----

SUBMISSION: 126
TITLE: Tratamiento de Señales Electroencefalográficas de Imaginación Motora con Fines de Clasificación
AUTHORS: Alexis Gallegos, Maria Dolores Torres Soto, Aurora Torres Soto and Eunice Esther Ponce de León Sentí

----- Overall evaluation -----

SCORE: 0 (borderline paper)

----- TEXT:

En este manuscrito se presentan los efectos de la normalización sobre la clasificación de series de tiempo provenientes de muestras electroencefalográficas de imaginación motora utilizando 2 tratamientos de datos: normalización y su descomposición en sus componentes de frecuencia usando la FFT. Este tratamiento es usado para clasificar entre dos señales de imaginación motora correspondientes a "abrir mano" y "cerrar mano". El trabajo es una aplicación interesante sobre el pre-procesamiento requerido para la clasificación de series de tiempo aplicado al estudio de señales electroencefalográficas, sin embargo existen los siguientes comentarios mayores:

*

Es un hecho bien conocido que para la clasificación y comparación de similitud de secuencias de series de tiempo, es un requisito la normalización de las series de tiempo (via z-score) para compararlas con las mismas amplitudes (10.1145/882082.882086). En este sentido, las comparaciones contra los datos crudos son irrelevantes y la anterior referencia debe ser incluida.

*

El resumen del trabajo necesita ser reescrito. El objetivo del resumen es presentar el problema a grandes rasgos, la propuesta del trabajo, los resultados y como estos contribuyen al desarrollo del conocimiento en la clasificación de series de tiempo. En su estado actual, no cumple con estas características.

*

<https://mail.google.com/mail/u/0/?ik=99ed18cdd9&view=pt&search=all&permthid=thread-f%3A1699527588634158110&siml=msg-f%3A1699527588...> 1/3

TESIS TESIS TESIS TESIS TESIS

TESIS TESIS TESIS TESIS TESIS

14/9/22, 11:38

Gmail - COMIA 2021 notificación del artículo 126

Las secciones del artículo deben ser Introducción, Materiales y Métodos, Experimentos, Conclusión/Discusiones. En su estado actual, el manuscrito no cumple con estas características.

La introducción debe mejorarse. El objetivo de esta sección es ampliar el resumen, con la misma secuencia que el resumen: problema detallado, las formas en las que se ha abordado este problema (estado del arte), la propuesta de los autores y la descripción del contenido del artículo. El estado del arte debe ser integrado en la introducción (imaginación motora); las señales encefalográficas sin la parte referente al hardware emotiv.

En la sección de materiales y métodos primero se deberá describir la metodología (fig.2) así como la descripción que la acompaña. Posteriormente se deben describir los materiales (base de datos de EEG, el hardware con el que se generaron los datos como la fig.3, y otros detalles relevantes como número de clases, proporciones, número de dimensiones, etc) y los métodos: normalización de la serie de tiempo; FFT removiendo la figura 1 ya que es una técnica ampliamente conocida y basta con utilizar una referencia; la sección 2.4 debería describir las máquinas de vectores de soporte (en su lugar se describe lo que es aprendizaje automático), parámetros de las SVM. En esta sección también debe describirse la configuración del experimento, las veces que se repitió, las proporciones de datos usadas (80% entrenamiento/20% validación). Estos conjuntos de datos son disjuntos? Falta clarificar.

En el sentido del comentario anterior, la presentación de los resultados puede mejorarse usando una de las siguientes dos formas: 1) el uso de una tabla donde se muestren las medias y desviaciones estandar para los algoritmos respecto a Recall, precisión, specificity y f1, o 2) con una figura que muestre la misma relación que la tabla, pero usando diagramas de violín (<https://seaborn.pydata.org/generated/seaborn.violinplot.html>, ej. figura 3). Esto permitirá sintetizar los resultados y compararlos de manera directa sin tener que estar cambiando de página.

Otros cambios menores son:

- * La figura 2 debe ser revisada, el último punto debería ser el análisis de resultados, no conclusiones.
- * En la sección de conclusiones y trabajo futuro, no se dice nada del trabajo futuro.

Por lo anterior recomiendo cambios mayores.

----- REVIEW 2 -----

SUBMISSION: 126

TITLE: Tratamiento de Señales Electroencefalográficas de Imaginación Motora con Fines de Clasificación

AUTHORS: Alexis Gallegos, Maria Dolores Torres Soto, Aurora Torres Soto and Eunice Esther Ponce de León Sentí

----- Overall evaluation -----

SCORE: 1 (weak accept)

----- TEXT:

El artículo presenta resultados de experimentos para el tratamiento de señales fisiológicas EEG, no hay una contribución evidente al estado del arte, el trabajo está bien estructurado y con una secuencia de ideas adecuada, para que el artículo sea publicado se recomiendan las siguientes correcciones:

1. Para darle un formato adecuado al documento se recomienda referenciar las ecuaciones, asignando un número al costado derecho (1), (2), ... haciendo referencia al número correspondiente, utilizar algún editor de formulas matemáticas para mejorar la calidad de las mismas.
2. En la sección 3 Metodología, no se menciona el tamaño de la muestra de usuarios de los que se recolectó datos crudos EEG, se infiere que fue solo uno, lo cual es una muestra no significativa y en su caso se analiza la señal de un solo sujeto de prueba. Esto se puede subsanar con el uso de dataset de señales EEG que pueden obtenerse en repositorios abiertos.
3. En la sección 4 Resultados, se recomienda modificar las gráficas y la redacción de los párrafos en donde se analizan los resultados evitando hacer referencia a los colores, se recomienda utilizar algún patrón en las gráficas para diferenciar ya que en ocasiones no se cuenta con versiones a color de los artículos lo cual dificulta distinguir los elementos en la gráfica.
4. Hay errores ortográficos menores que es necesario corregir, por ejemplo, se omiten los acentos en éste cuando tiene la función de sustantivo.
5. Hay errores de redacción menores que es necesario corregir, se adjunta el documento con algunos ejemplos.

<https://mail.google.com/mail/u/0/?ik=99ed18cdd9&view=pt&search=all&permthid=thread-f%3A1699527588634158110&simpl=msg-f%3A1699527588...> 2/3

14/9/22, 11:38

Gmail - COMIA 2021 notificación del artículo 126

6. Para complementar el trabajo de investigación es recomendable que se exploren otros algoritmos de clasificación que han demostrado en la literatura mejores resultados, en este caso Redes Neuronales y RF. Buscar dataset de entrenamiento disponibles en repositorios abiertos.

Alexis Gallegos <alexisedm@gmail.com>

12 de mayo de 2021, 9:19

Para: "Dra. María Dolores Torres Soto" <mdtorres@correo.uaa.mx>, "M.C. Aurora Torres Soto" <atorres@correo.uaa.mx>

Buen día,

Le hago llegar el resultado de la evaluación del artículo para COMIA
Saludos,

Alexis

[El texto citado está oculto]

Dra. Aurora Torres <atorres@correo.uaa.mx>

13 de mayo de 2021, 10:56

Para: Alexis Gallegos <alexisedm@gmail.com>

Ok. Saludos

[El texto citado está oculto]

Feature Subset Selection in Electroencephalographic signals using typical testors

Alexis Gallegos, Dolores Torres, Aurora Torres

Benémerita Universidad Autónoma de Aguascalientes, Aguascalientes, México
alexisedm@gmail.com, {mdtorres, atorres}@correo.uaa.mx

Abstract. Motor imagery (MI) is a mental representation of movement without performing it or even tensing any muscles. MI requires a conscious activation of the same brain regions that involved in actual movement. The use of brain signals has been explored for multiple applications on the field of biomedical engineering such as the development of brain computer interfaces (BCI). BCI systems are designed to translates users' intentions into control signals, commands, or codes. Nevertheless, the major challenge in BCI system development is the classification of MI signal recorded by an electroencephalogram (EEG). This paper focuses on the application of the testor theory and the logical combinatorial pattern recognition approach for feature selection with the aim of reducing the feature representation space for classification tasks. The MI-EEG signals were recorded by the EMOTIV EPOC+ EEG device with 14 electrodes.

Keywords. Typical testors, feature subset selection, electroencephalographic signals, motor imagery

1 Introduction

This paper focuses on the application of testor theory and the logical combinatorial pattern recognition approach for feature selection. The problem of selecting the subset of features that best describes a phenomenon from a larger set allows to reduce the size of solution space, so that results close to the optimum or the optimum itself are obtained with less resources (time and memory)[1].

Therefore, the aim of the paper was to reduce the MI-EEG (Motor Imagery Electroencephalographic) signals feature representation space for classification tasks. These signals were recorded by the Emotiv EPOC+ device which describes the signals by means of 14 electrodes distributed over the scalp.

The EEG signals represent the electrical brain activity created by billions of neurons [2]. This activity represents the communication between the body and the brain. The analysis of EEG signals is highly relevant in health research for diagnosis, treatment, and monitoring of different diseases [2], [3].

On the other hand, motor imagery, or MI, is a mental performance of movement without any physical activation. The movements analyzed were opening and closing of the hand. The practice of MI is used in the context of sports as well as in rehabilita-



Article ID: 19
Subject: Final Verdict
Date: October 21, 2021

XIV HIS MICA I 2021

Authors(s): Alexis Gallegos, Dolores Torres, and Aurora Torres

I hereby write to you to inform you that the work entitled “**Feature Subset Selection in Electroencephalographic signals using typical testors**” with ID 19, submitted for the “**XI Workshop of Hybrid Intelligent Systems**” to be held on **October 25-26, 2021** during the MICA I 2021 Workshops day, **was Accepted with Observations**, and will be published in a special volume of the journal Research in Computing Science ISSN 1870-4069, in accordance with the following observations:

Reviewer 1 Verdict: Accepted with Observations
Recommendations:
<ul style="list-style-type: none"> •The article “HIS2021_paper_19” should be rewritten in tables and the reference section. In addition, only one line break is missing in the text (above Table 1). •Furthermore, authors should reduce the plagiarism score. •The reference format should be corrected. •Tables format should be corrected, Rows and captions. •The article is well supported by the literature. •The articles present research with conclusive results.

Reviewer 2 Verdict: Accepted with Observations
Recommendations:
It is necessary to improve the figures and make a more detailed multivariate analysis in order to better understand the main objective of the research.

Reviewer 3 Verdict: Accepted with Observations
Recommendations:
Authors must make the changes indicated in the reviews.

If you have been accepted, we ask you to pay special attention to the dates and requirements published in the page <http://www.edgarcossio.mx/his2021/>

The publication fee amount for accepted papers is \$1,000 MXN. Please transfer the fee to any of the following accounts in Mexican pesos to:

Bank: BBVA Bancomer, Account: 0194625285, CLABE: 012180001946252858, Beneficiary: Sociedad Mexicana de Inteligencia Artificial, A.C.

or

Bank: BANAMEX, Branch: 4152, Account: 0194825, CLABE: 002180415201948254, Beneficiary: Sociedad Mexicana de Inteligencia Artificial, A.C.

As payment details please use:





Article ID: 19
Subject: Final Verdict
Date: October 21, 2021

Workshop authors: "MICAI 2021 workshop (workshop abbreviation) paper (paper title or first several words of it)", for example: "MICAI 2021 workshop HIS paper Solving the capacitated vehicle routing problem in a shared bicycle system of a smart city".

If you pay from abroad, please make sure that the complete fee is deposited to our account; i.e., if there is any transfer fee, please add it to your payment.

Upon payment, please send a message at martin.montes@upa.edu.mx, with the subject "Payment MICAI 2021 paper (your paper ID)", and attach the payment proof (either a receipt generated by the online system or a scanned image of a physical receipt). In the body of the message please indicate the paper number and title.

Thanking you for your valuable attention to this letter, I send you cordial and respectful greetings.

A handwritten signature in blue ink, appearing to be "Dr. Martín Montes Rivera", written over a horizontal line.

Dr. Martín Montes Rivera

CHAIR

XIV Workshop of Hybrid Intelligent Systems



Feature Selection in Electroencephalographic Signals Using a Multicriteria Decision Analysis Method

Alexis Edmundo Gallegos Acosta¹ [0000-0002-6404-5289], María Dolores Torres Soto¹, Aurora Torres Soto¹, Eunice Esther Ponce de León Senti¹, Carlos Alberto Ochoa Ortiz Zezzatti²

alexisEdm@gmail.com, {mdtorres, atorres, eponce}@correo.uaa.mx, alberto.ochoa@uacj.mx

¹ Benemérita Universidad Autónoma de Aguascalientes, México

² Universidad Autónoma de Ciudad Juárez, México

Abstract. In recent years, industry 4.0 has promoted the rise of new technologies and devices that generate and collect data both in industry and everyday life. As a result, there is a new challenge of creating robust tools that facilitate the analysis of this information. Feature selection allows the efficient extraction of features that describe objects or phenomena, by removing distractors and redundant information. Thus, classification and decision-making models can be created with stable representations. In this chapter, a set of typical testors was extracted from a database with motor imagery EEG signals employing the testor theory, an approach to feature selection. A typical testor is the smallest possible combination of features that allow objects to be differentiated belonging to different classes. The purpose of this chapter is to select the typical testor with the best performance in an ANN classifier employing TOPSIS, a multicriteria decision analysis method.

Keywords: TOPSIS, EEG Signals, Artificial Neural Network, Typical Testors Theory, Motor Imagery, Industry 4.0

1 Introduction

Since the introduction of the industry 4.0 concept in 2011, changes in technology and society have been taking place. This new paradigm favors the integration of technologies and their digitalization using intelligent systems [1]–[3]. This new universe of applications and technologies brings with it support in the daily life of users with new infrastructures for access to culture, leisure, education, commerce, and healthcare services, to highlight some approaches [1], [4].

Technology has evolved enough to have the capacity to process large amounts of information, which is a crucial trend in the industry 4.0 approach [5]. However, it also resulted in the generation and availability of an uncountable amount of data. The complexity of data processing of the dataset increase and, therefore, the greater the challenge to detect and exploit the relationships between the features of the dataset [6]. Consequently, the processing and analysis of information require increasingly complex models with higher computational costs [6], [7]. Under this context, there are two



Dear Alexis Gallegos,

We are pleased to inform you that your manuscript,

Paper ID: 7148

Title: Feature Selection in Electroencephalographic Signals Using a Multicriteria Decision Analysis Method

Authors: *Alexis Gallegos, María Dolores Torres Soto, Aurora Torres Soto, Eunice Esther Ponce De León Sentí, Alberto Ochoa-Zezzatti.

has been accepted for publication in Innovation and Competitiveness in Industry 4.0 Based on Intelligent Systems. The reviewers' reports have been attached at the bottom of this email.

Please upload a final, camera-ready version as approved by Editor:

<https://escripts.eai.eu/paper/lists?accepted>

Please make sure that your paper follows the [instructions](#) and is in the correct [EAI Endorsed Transactions template](#). A manuscript in a different template will be sent back for correction.

After signing the copyright agreement we will proceed with the publication of your article.

Thank you for submitting your work to Innovation and Competitiveness in Industry 4.0 Based on Intelligent Systems.

For your efforts as an Author, you receive 10 points based on the average review score of your submission as evaluated by Reviewers and supervised by the Handling Editor. These points count toward your EAI Index.

EAI Index represents a revolution in recognizing excellence in research fairly and transparently, and it is a key element in annual nominations for the member ranks of EAI Fellows, Distinguished Members, and Senior Members. You can view your current EAI Index in your [user profile](#) at any time and gain more points by volunteering in other EAI conferences and journals, or by submitting papers to these research venues:

- Bid to Review recently submitted papers in [Community Review](#)
- See [open positions](#) in conferences and journals
- Explore [conferences](#) and [journals](#) open for submission

To learn more about EAI's transparent research recognition program, please visit the [EAI website](#).

Best Regards,

Publication Department | European Alliance for Innovation
publications@eai.eu | www.eai.eu

Reviewers comments:

*** REFEREE 3 REPORT ***

=====

** Below you can find comments on each criterions **

1 . Novelty of the contribution

...

2 . Innovation impact of the proposed concept

...

3 . Technical content and correctness of the contribution

...

4 . Importance of the manuscript for the thematic area

...

5 . Implementation potential of the proposed concept

...

6 . Completeness of the references

...

7 . Quality of the writing

...

** General comments by referee 3 to Author**

Excellent work, very innovative, and well designed! Congratulations.

*** REFEREE 2 REPORT ***

=====

**** Below you can find comments on each criterions ****

1 . Novelty of the contribution

...

2 . Innovation impact of the proposed concept

...

3 . Technical content and correctness of the contribution

...

4 . Importance of the manuscript for the thematic area

...

5 . Implementation potential of the proposed concept

...

6 . Completeness of the references

...

7 . Quality of the writing

...

**** General comments by referee 2 to Author****

The recommendations from previous review round were attended, however some images needs to be improved, for example Fig. 4 & Fig. 6 have quality resolution problems.

***** REFEREE 1 REPORT *****

=====

**** Below you can find comments on each criterions ****

1 . Novelty of the contribution

It is good work. A small recommendation is to do a deep literature review on MCDM methods

2 . Innovation impact of the proposed concept

The paper represents a good innovation due to the field involved in application study.

3 . Technical content and correctness of the contribution

The paper addressed a good numerical case to explain the proposal.

4 . Importance of the manuscript for the thematic area

The implementation to explore new applications

5 . Implementation potential of the proposed concept

The paper conduced to replicate the proposal for new problem

6 . Completeness of the references

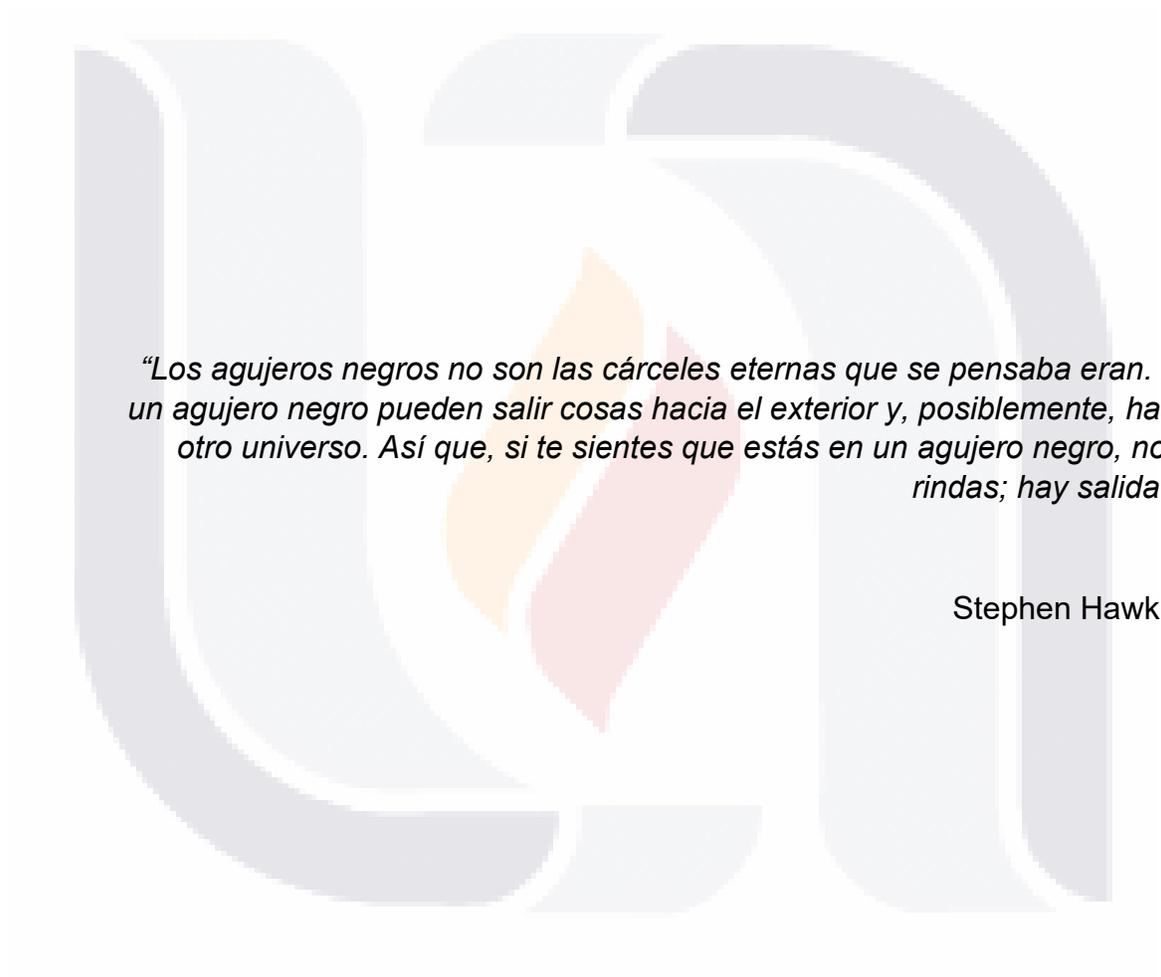
Good

7 . Quality of the writing

It represent a good material

** General comments by referee 1 to Author**

It is good work. A small recommendation is to do a deep literature review on MCDM methods



“Los agujeros negros no son las cárceles eternas que se pensaba eran. De un agujero negro pueden salir cosas hacia el exterior y, posiblemente, hacia otro universo. Así que, si te sientes que estás en un agujero negro, no te rindas; hay salida...”

Stephen Hawking

“Dada la inmensidad del tiempo y la inmensidad del universo, es un placer inmenso para mí compartir un planeta y un tiempo contigo”

Carl Sagan

Agradecimientos

A la vida, por mantenerme aquí, por poner a las personas adecuadas a mi lado, por las experiencias, por los errores, las caídas, la oscuridad y la luz... Gracias por seguir dándome la oportunidad de levantarme, crecer y aprender.

A todas y cada una de las personas que se involucraron en la realización de este proyecto. A las personas que me alentaron y creyeron en mí, antes que yo. Muchas gracias.

A mis padres, Edmundo y Tere; y a mis hermanos Luis, Amairani y mi hermano por elección, Israel.

A Fernando Muñoz, Gabriela Cabral, Paulina Pérez, Jorge Acosta, Stephanye Santacruz, Andrea Ruíz, Pablo Cuellar, Mariana Cuellar, Diana Cuellar, Andrea Cuellar, Paloma Reyes, Manuel Díaz, Francisco Palma y Pablo Rodríguez.

A mis profesores y mentores: la Dra. María Dolores Torres Soto, la Dra. Aurora Torres Soto, la Dra. Eunice Esther Ponce de León Sentí y al Dr. José Luis Quintanar Stephano.

A la Universidad Autónoma de Aguascalientes y al Conacyt por abrir sus puertas y permitirme vivir esta experiencia.

Dedicatoria

Dedico este trabajo, como fruto del esfuerzo y constancia, a aquellas personas que me impulsaron a continuar cuando estaba seguro de que ya no podía. Sobre todo, no se imaginan lo que he aprendido de ustedes en esta etapa de mi vida y lo que significa para mí.

A mis padres, que sentaron las bases para llegar a este momento.

A mis hermanos, mis compañeros en el camino.

Contenido

Índice de figuras.....	6
Índice de tablas	10
Índice de ecuaciones	12
Resumen.....	14
Abstract.....	16
1. Introducción.....	19
1.1 Problema.....	21
1.2 Justificación	21
1.3 Hipótesis.....	24
1.4 Objetivos	24
1.4.1 Objetivo general.....	24
1.4.2 Objetivos particulares.....	24
2. Marco Teórico	25
2.1 Antecedentes.....	25
2.2 Cerebro humano.....	27
2.2.1 Corteza cerebral.....	28
Lóbulo frontal.....	29
Lóbulo parietal	32
Lóbulo temporal.....	34
Lóbulo occipital.....	36
2.2.2 Ganglios basales.....	37
2.2.3 Cerebelo	40
2.2.4 Neurona biológica	43
2.3 Intención de movimiento.....	46
2.3.1 Bases neurofuncionales.....	48
2.4 Electroencefalograma.....	55
2.5 Interfaz cerebro-computadora	58

2.5.1 Elementos en una interfaz cerebro-computadora	59
2.5.2 Clasificación de sistemas BCI.....	62
2.6 Reconocimiento de patrones	66
2.7 Selección de características	70
2.7.1 Teoría de testores	71
2.7.2 Modelo exhaustivo para la obtención de testores y testores típicos	73
2.8 Heurísticas y metaheurísticas.....	76
2.8.1 Heurísticas	77
2.8.2 Metaheurísticas.....	78
2.9 Aprendizaje automático	79
2.9.1 Elementos en un problema de aprendizaje automático	82
2.9.2 Tipos de aprendizaje automático	85
2.9.3 Clasificación de algoritmos de aprendizaje automático.....	87
2.10 Regresión	90
2.11 Clasificación	91
2.11.1 Evaluación de un modelo de clasificación.....	92
2.12 Modelos de Clasificación	95
2.12.1 Naive Bayes (NBC).....	95
Construcción de un clasificador bayesiano simple	96
2.12.2 Redes neuronales artificiales	98
2.12.3 Máquinas de soporte vectorial	106
Caso linealmente separable (SVM de margen máximo)	107
Caso cuasi-linealmente separable (SVM de margen flexible)	110
Caso no lineal.....	112
2.13 Técnicas de procesamiento de señales.....	114
2.13.1 Transformada de Fourier	114
2.14 Métodos de toma de decisiones multicriterio.....	116
2.14.1 TOPSIS.....	120
3. Propuesta metodológica para la obtención y manipulación de señales EEG-MI	124

4. Implementación y resultados de la propuesta metodológica.....	129
4.1 Fase 1.....	129
4.2 Fase 2.....	133
4.2.1 Emotiv EPOC+	133
4.2.2 Búsqueda de repositorios con señales EEG.....	135
4.2.3 Desarrollo de protocolo de captura de datos EEG	136
Consideraciones ambientales	137
4.2.4 Captura de señales preliminares	138
4.3 Fase 3.....	139
4.3.1 Captura de señales EEG-MI	139
4.3.2 Análisis de correlaciones	141
4.3.3 Análisis de selección de subconjuntos de características.....	143
Búsqueda de testores típicos por medio de metaheurísticas evolutivas ..	143
Primera aplicación de la teoría de testores	158
Segunda aplicación de la teoría de testores.....	161
4.4 Fase 4.....	163
4.4.1 Implementación de algoritmos ML con repositorio de estado de ojo ..	163
Implementación de Naive Bayes (clasificador bayesiano simple)	163
Implementación de una red neuronal artificial	166
4.4.2 Afinación de parámetros en modelos de aprendizaje automático	167
4.4.3 Transformación de señales EEG-MI	174
4.4.4 Selección de testores típicos por medio de métodos para la toma de decisiones multicriterio.....	184
4.5 Fase 5.....	190
4.5.1 Selección de protocolo de captura	191
4.5.2 Selección de método de preprocesamiento	191
4.5.3 Representación de datos	193
4.5.4 Selección de subconjuntos de características	193
4.5.5 Diseño y evaluación de la red neuronal artificial	194
4.6 Fase 6.....	199

4.7 Productos	203
4.7.1 Publicaciones.....	203
4.7.2 Asesorías	205
4.7.3 Eventos.....	206
4.7.4 Docencia.....	207
5. Conclusiones.....	208
Bibliografía	213
Anexos	244
A. Publicaciones.....	244
A.1 Integración del operador de alteración a metaheurísticas evolutivas para la aplicación de la teoría de testores en patologías médicas.....	244
Resumen	244
Palabras clave.....	245
A.2 Clasificación de señales electroencefalográficas por medio de un clasificador bayesiano.....	246
A.3 Manipulación de metaheurísticas para la búsqueda de testores típicos	247
Resumen	247
A.4 Contrastación de algoritmos de aprendizaje automático para la clasificación de señales EEG	249
Resumen	249
Palabras clave.....	249
A.5 Tratamiento de señales electroencefalográficas de imaginación motora con fines de clasificación	261
Resumen	261
Palabras clave.....	261
A.6 Procesamiento y clasificación de señales electroencefalográficas con imaginación motora.....	265
A.7 Feature subset selection in electroencephalographic signals using typical testors	266
Resumen	266
Palabras clave.....	266

A.8 Feature selection in electroencephalographic signals using a multicriteria decision analysis method..... 269

 Resumen 269

 Palabras clave..... 270

A.9 Toma de decisiones en testores típicos de señales EEG con intención de movimiento..... 274



Índice de figuras

Figura 1. Vista lateral de la corteza cerebral. Obtenida de [34].....	29
Figura 2. Lóbulo frontal. Obtenida de [39].	30
Figura 3. Homúnculo motor y sensorial de Penfield. Obtenida de [42].....	31
Figura 4. Lóbulo parietal. Obtenida de [44].	32
Figura 5. Lóbulo temporal. Obtenida de [50].	34
Figura 6. Lóbulo Occipital. Obtenida de [51].	36
Figura 7. Ganglios o núcleos basales. Obtenida de [57].	37
Figura 8. Cerebelo. Obtenida de [66].	40
Figura 9. Composición de la neurona biológica. Imagen basa en los trabajos de [29], [86], [88].	44
Figura 10. Intención de movimiento. Obtenida de [97].	46
Figura 11. Muestras de fMRI durante intención de movimiento y práctica física de tareas con miembro superior. Obtenida de [102].	48
Figura 12. Esquematización de la actividad cerebral durante la intención de movimiento. Traducción y adaptación del original publicado en [103].	49
Figura 13. Zonas cerebrales específicas activadas durante intención de movimiento visual (rojo) y cinestésico (azul). Obtenida de [102], [103].	50
Figura 14. Áreas de la corteza frontal involucradas en intención de movimiento. Obtenida de [108].	51
Figura 15. Estructura de un sistema de interfaz cerebro-computadora. Basado en los diagramas publicados en [145]–[147].	59
Figura 16. Métodos para el registro de la actividad cerebral. Extraído de [152]... ..	62
Figura 17. Clasificación de sistemas de interfaz cerebro-computadora. Obtenida de [139].	64
Figura 18. Proceso de reconocimiento de patrones para clasificación. Basado en [160].	69
Figura 19. Conjunto de características, testores y testores típicos. Obtenida de [157].	72
Figura 20. Obtención de testores a partir del conjunto potencia. Obtenida de [175].	75

Figura 21. Relación entre inteligencia artificial, aprendizaje automático, redes neuronales artificiales, aprendizaje profundo y minería de datos. Traducción del original publicado en [214]. 80

Figura 22. Contraste entre programación clásica y el aprendizaje automático. Basado en los diagramas publicados en [207], [217], [218]. 82

Figura 23. Categorías de los algoritmos de aprendizaje automático según la naturaleza de los datos de entrenamiento. Obtenida de [212]. 87

Figura 24. Aprendizaje supervisado. Obtenida de [227]. 88

Figura 25. Aprendizaje no supervisado. Traducido y adaptado del original publicado en [228]. 88

Figura 26. Enfoques y aplicaciones del aprendizaje automático. Obtenida de [214]. 89

Figura 27. División de datos simple para un modelo de aprendizaje automático. Obtenida de [217]. 92

Figura 28. Clasificador bayesiano simple. Obtenida de [244], [246]. 96

Figura 29. Comparación entre una neurona biológica (izquierda) y una neurona artificial (derecha). Réplica basada en la publicada por [86]. 98

Figura 30. Neurona artificial. Obtenida de [259]. 100

Figura 31. Funciones de activación más comunes [258], [260]. 101

Figura 32. Red neuronal artificial. Obtenida de [263]. 102

Figura 33. Arquitecturas de deep learning más comunes. Obtenida de [265]. ... 105

Figura 34. (A) Posibles hiperplanos de separación. (B) Hiperplano de separación óptimo (HSO) [268], [269], [275]. 107

Figura 35. Problema cuasi-separable. Obtenida de [274]. 110

Figura 36. Mapeo de datos. (A) Espacio de entrada. (B) Espacio de características y HSO. Obtenida de [268]. 112

Figura 37. Transformada discreta de Fourier. Obtenida de [286]. 115

Figura 38. Publicaciones orientadas a métodos MCDM, 1990-2017. Extraído de [305]. 119

Figura 39. Metodología. 125

Figura 40. Emotiv EPOC+ (Figura tomada de la web oficial [310]). 131

Figura 41. Sistema 10-20 y Distribución de electrodos del Emotiv EPOC+ [310], [312]. 132

Figura 42. Especificaciones detalladas del dispositivo Emotiv EPOC+ [286], [310].
 133

Figura 43. (A) Interfaz de Cykit [313] y (B) Funcionamiento de OpenVibe (imagen propia). 134

Figura 44. Protocolo de captura de señales EEG en su primera versión. 136

Figura 45. Segunda versión del protocolo de captura de señales EEG-MI. 137

Figura 46. Análisis de correlaciones. Publicado en anexo A.8. 142

Figura 47. Metodología para la búsqueda de testores típicos por medio de la hibridación de metaheurísticas evolutivas. Publicado en [320]. 144

Figura 48. Algoritmo interno del operador de alteración. Publicado en [320]. 147

Figura 49. Generación de nuevas poblaciones en metaheurísticas híbridas. Publicado en [320]. 148

Figura 50. Cálculo de testores típicos en señales EEG-MI. Publicado en Anexo A.7
 158

Figura 51. Comportamiento del peso informacional en los electrodos del EPOC+. Imagen tomada de [150] y modificada para presentar pesos informacionales. .. 162

Figura 52. Configuración de red neuronal multicapa en su primer acercamiento.
 166

Figura 53. Ajuste de parámetros RNA y SVM para clasificar señales EEG. Publicado en [333]. 168

Figura 54. Tratamiento de señales y análisis de desempeño de SVM. Publicado en Anexo A.5. 175

Figura 55. (A) Señal en crudo. (B) Señal transformada por FFT. Publicado en Anexo A.5. 177

Figura 56. Exactitud (Modelos SVM). Publicado en Anexo A.5. 179

Figura 57. Precisión (Modelo SVM). Publicado en Anexo A.5. 180

Figura 58. Sensibilidad (Modelo SVM). Publicado en Anexo A.5. 181

Figura 59. Especificidad (Modelo SVM). Publicado en Anexo A.5. 182

Figura 60. Puntuación F1 (modelo SVM). Publicado en Anexo A.5. 182

Figura 61. Análisis TOPSIS. Publicado en inglés en Anexo A.8. 184

Figura 62. Modelo híbrido de clasificación. 190

Figura 63. Protocolo de captura de señales EEG-MI aplicado en el modelo MHH-FSS-RNA. 191

Figura 64. Brazo mecánico para la etapa de prueba de la Fase 6..... 199

Figura 65. Código para para la placa Arduino del brazo mecánico..... 201



Índice de tablas

Tabla 1. Frecuencias de ondas cerebrales [122], [131]	56
Tabla 2. Matriz de confusión [240].	93
Tabla 3. Métodos de toma de decisiones multicriterio [297], [299], [302]	118
Tabla 4. Comparación de dispositivos EEG comerciales.	129
Tabla 5. Nomenclatura del sistema internacional 10-20. Obtenida del trabajo de [286].	132
Tabla 6. Descripción del repositorio de detección del estado del ojo con señales EEG.	135
Tabla 7. Características de sujeto de prueba para señales preliminares	138
Tabla 8. Descripción de repositorio preliminar de intención de movimiento	139
Tabla 9. Repositorio de señales EEG-MI de abrir/cerrar mano derecha	140
Tabla 10. Desviaciones estándar. Publicado en anexo A.8.	141
Tabla 11. Escenarios de experimentación, características y pesos informacionales. Publicado en [320].	150
Tabla 12. Factores y niveles del diseño de experimentos. Publicado en [320]....	151
Tabla 13. Pruebas estadísticas y mejores experimento de AG híbrido para células de cáncer de mama y casos de hemofilia. Publicado en [320].	152
Tabla 14. Pruebas estadísticas y mejores experimento de AG híbrido para células de cáncer de mama y casos de hemofilia. Publicado en [320].	154
Tabla 15. Contrastación de metaheurísticas híbridas en el contexto de cáncer de mama y hemofilia. Publicado en [320].	156
Tabla 16. Testor típico en señales EEG-MI con intención de movimiento. Publicado en Anexo A.7.	159
Tabla 17. Peso informacional. Publicado en Anexo A.7	160
Tabla 18. Segundo conjunto de testores típicos y el cálculo de peso informacional. Publicada en Anexo A.8.	161
Tabla 19. Tabla de confusión para el clasificador bayesiano simple.	164
Tabla 20. Métricas de desempeño del clasificador bayesiano simple.	164
Tabla 21. Repositorio de datos para afinación de parámetros.	167

Tabla 22. Parámetros SVM para la afinación de clasificación de intención de movimiento. Publicado en [333]. 169

Tabla 23. Parámetros RNA para imaginación motora. Publicado en [333]. 170

Tabla 24. Mejores modelos SVM y RNA. Publicado en [333]. 172

Tabla 25. Parámetros del modelo SVM. Publicado en Anexo A.5. 178

Tabla 26. Modelo de red neuronal artificial para análisis TOPSIS. Publicado en Anexo A.8..... 184

Tabla 27. Conjunto de testores típicos de señales EEG-MI (abrir y cerrar mano). Publicado en Anexo A.8. 185

Tabla 28. Matriz de decisión y vector de pesos. Publicada en Anexo A.8. 185

Tabla 29. Matriz de decisión normalizada. Publicada en Anexo A.8. 186

Tabla 30. Matriz de decisión ponderada. Publicada en Anexo A.8..... 187

Tabla 31. Solución ideal y solución no-ideal. Publicada en Anexo A.8..... 187

Tabla 32. Distancias a la solución ideal y a la solución no-ideal. Publicada en Anexo A.8..... 188

Tabla 33. Cercanías relativas. Publicada en Anexo A.8. 188

Tabla 34. Resultados TOPSIS (Ranking de alternativas). Publicado en Anexo A.8. 188

Tabla 35. Testor típico seleccionado por TOPSIS. 193

Tabla 36. Modelo de red neuronal artificial para modelo MHH-FSS-RNA. 194

Tabla 37. Modelos de clasificación 195

Índice de ecuaciones

(1).....	74
(2).....	76
(3).....	83
(4).....	90
(5).....	93
(6).....	93
(7).....	94
(8).....	94
(9).....	94
(10).....	95
(11).....	95
(12).....	97
(13).....	97
(14).....	101
(15).....	108
(16).....	108
(17).....	108
(18).....	108
(19).....	109
(20).....	109
(21).....	109
(22).....	110
(23).....	111
(24).....	111
(25).....	112
(26).....	113
(27).....	113

(28).....	114
(29).....	115
(30).....	120
(31).....	120
(32).....	120
(33).....	121
(34).....	121
(35).....	121
(36).....	121
(37).....	122
(38).....	122
(39).....	122
(40).....	122
(41).....	123
(42).....	149
(43).....	159
(44).....	161
(45).....	192
(46).....	195
(47).....	195
(48).....	195

Resumen

La intención de movimiento comprende la representación mental de movimiento sin la ejecución real. Se trata de un mecanismo neurológico endógeno que comprende la realización interna de una tarea mental que provoca cambios en la actividad bioeléctrica del cerebro. El trabajo de tesis reportado en este documento expone el desarrollo e implementación de un mecanismo híbrido, denominando MHH-FSS-RNA, basado en metaheurísticas para la clasificación de señales electroencefalográficas con intención de movimiento cinestésico (EEG-MI) el cual, aprovecha los cambios en la actividad bioeléctrica del cerebro para la identificación de la intención de abrir y cerrar la mano derecha.

Para el diseño del mecanismo MHH-FSS-RNA se siguió una metodología propuesta, constituida por fases y que permitió el desarrollo de un mecanismo de un clasificador de intención de movimiento. Dicho clasificador fue validado con la manipulación de un brazo mecánico que obedece a la intención de movimiento a través de señales electroencefalográficas.

La primera de las fases de la metodología propuesta consistió en la selección del dispositivo Emotiv EPOC+ de catorce electrodos para la captura de las señales EEG-MI. Este dispositivo tiene la ventaja de ser comercial y permitir la lectura de una amplia zona de cuero cabelludo siguiendo el sistema internacional 10-20 para la colocación de electrodos de electroencefalograma. Gracias a este dispositivo se logró, además, la construcción de diferentes repositorios utilizados para experimentaciones y, consiguientes implementaciones.

Partiendo de repositorios de datos disponibles para investigación de forma abierta, se realizó un análisis de diferentes técnicas de preprocesamiento y de selección de características con el objetivo de facilitar su clasificación. Las técnicas de preprocesamiento estudiadas fueron la transformada rápida de Fourier y la normalización Z-score. Donde la normalización, resultó ser la más adecuada al

permitir un mejor desempeño de clasificación. Para la selección de características se aplicó la teoría de testores con la cual, se obtuvo un conjunto de testores típicos. Este conjunto de testores típicos permitió reducir la dimensionalidad del problema y, por lo tanto, disminuir los requerimientos computacionales para su procesamiento y clasificación. Sin embargo, cabe destacar que encontrar el conjunto de testores típicos permitió conocer aquellos nodos determinantes en la lectura de la intención de abrir y cerrar la mano derecha. A partir del conjunto de testores típicos, se seleccionó uno de acuerdo con el desempeño de clasificación. Todo ello, analizando las métricas obtenidas de la construcción de una matriz de confusión por medio de un estudio de TOPSIS, un método para la toma de decisiones multicriterio.

La metodología propuesta continuó con el análisis de modelos metaheurísticos de clasificación: las máquinas de soporte vectorial y las redes neuronales artificiales. Este análisis permitió conocer el desempeño y comportamiento de la clasificación de ambas intenciones de movimiento. Esta sección permitió la afinación de parámetros en ambas metaheurísticas con el objetivo de beneficiar el desempeño en la clasificación, por medio de un diseño de experimentos factorial.

Al final de esta investigación se contó con un mecanismo híbrido basado en metaheurísticas para la clasificación de señales EEG-MI designado como MHH-FSS-RNA. Este modelo obedece a un testor típico compuesto por aquellos nodos/electrodos del dispositivo Emotiv que inciden de forma determinante en la descripción de las intenciones de abrir/cerrar la mano. El modelo cuenta, además, con una red neuronal artificial con parámetros afinados encaminados a un alto desempeño de clasificación. El mecanismo MHH-FSS-RNA fue aplicado al control de un brazo mecánico con cual, se le dio la capacidad de responder a registros de electroencefalograma que evocan la intención de movimiento de abrir y cerrar la mano derecha de un sujeto de prueba, pues, al ser señales complejas y completamente personales, el mecanismo debe ser entrenado y afinado para cada usuario.

Abstract

Movement intention is the mental representation of movement without actual execution. It is an endogenous neurological mechanism involving the internal performance of a mental task that causes changes in the bioelectrical activity of the brain. The present thesis research paper presents the development and implementation of a hybrid mechanism, called MHH-FSS-RNA, based on metaheuristics for the classification of electroencephalographic signals with kinesthetic movement intention (EEG-MI), which takes advantage of changes in the bioelectrical activity of the brain for the identification of the intention to open and close the right hand.

For the design of the MHH-FSS-RNA mechanism, a proposed methodology was followed, which consisted of phases and allowed the development of a movement intention classifier mechanism. This classifier was validated with the manipulation of a mechanical arm that obeys the movement intention through electroencephalographic signals.

The first phase of the proposed methodology consisted in the selection of the Emotiv EPOC+ device with fourteen electrodes to capture EEG-MI signals. This device has the advantage of being commercial and allowing the reading of a wide scalp area following the international 10-20 system for the placement of electroencephalogram electrodes. Thanks to this device, the construction of different repositories used for experimentation and, consequent implementations, was also achieved.

Based on openly available data repositories for research, an analysis of different preprocessing and feature selection techniques was carried out to facilitate their classification. The preprocessing techniques studied were the fast Fourier transform and Z-score normalization. Where normalization proved to be the most appropriate as it allowed a better classification performance. For feature selection, the testor

theory was applied to obtain a set of typical testors. This set of typical testors allowed for the reduction of the dimensionality of the problem and, therefore, reduced the computational requirements for its processing and classification. However, it should be noted that finding the set of typical testors allowed us to know those nodes that were determinant in the reading of the intention to open and close the right hand. From the set of typical testors, one was selected according to the classification performance. All this, analyzing the metrics obtained from the construction of a confusion matrix by means of a TOPSIS study, a method for multi-criteria decision-making.

The proposed methodology continued with the analysis of metaheuristic classification models: support vector machines and artificial neural networks. This analysis allowed to know the performance and classification behavior of both movement intentions. This section allowed the tuning of parameters in both metaheuristics with the objective of benefiting the classification performance, by means of a factorial design of experiments.

At the end of this research, a hybrid mechanism based on metaheuristics for the classification of EEG-MI signals, designated as MHH-FSS-RNA, was implemented. This model obeys a typical testor composed of those nodes/electrodes of the Emotiv device that have a determining influence on the description of the intentions to open/close the hand. The model also has an artificial neural network with tuned parameters aimed at high classification performance. The MHH-FSS-RNA mechanism was applied to the control of a mechanical arm with which it was given the ability to respond to electroencephalogram recordings that evoke the movement intention of opening and closing the right hand of a test subject, since, being complex and completely personal signals, the mechanism must be trained and tuned for each user.



Capítulo I

Introducción

EL presente trabajo de tesis se enfoca en la creación de un método para la manipulación de señales electroencefalográficas que considera el desarrollo de un mecanismo híbrido de clasificación de señales electroencefalográficas (EEG), denominado MHH-FSS-RNA y enfocado en la distinción de dos intenciones de movimiento cinestésico: abrir y cerrar la mano derecha. El mecanismo mencionado fue construido a partir de la lectura de señales EEG por medio del dispositivo Emotiv EPOC+ compuesto por catorce señales, el cual, permitió la medición de los potenciales que reflejan la actividad eléctrica del cerebro. Así mismo, el modelo se distingue por obedecer a aplicación de la teoría de testores, una técnica para la selección de subconjuntos de características bajo el enfoque lógico-combinatorio del reconocimiento de patrones. De esta manera, se reduce la dimensionalidad del problema determinado aquellas características que resultan determinantes en un proceso de clasificación y, por consiguiente, un requerimiento menor de recursos computacionales.

La teoría de testores permitió la obtención de un conjunto de testores típicos, donde cada uno de ellos representa un subconjunto mínimo necesario para clasificación de las intenciones de movimiento involucradas. Lo que significa que posibilitan la discriminación de características cuya información no es determinante para describir objetos e identificarlos como miembros de una clase en particular. Para seleccionar el más adecuado, se hizo uso de TOPSIS, un método para la toma de decisiones multicriterio que analiza diferentes alternativas tomando en cuenta criterios que, incluso, pueden ser incompatibles. Este estudio se realizó en función al desempeño obtenido por mecanismos de clasificación como las redes neuronales artificiales.

Este reporte de tesis se compone de cinco apartados. En el apartado actual se exponen el problema, la justificación y los objetivos, tanto generales como particulares, a lograr con el desarrollo de la presente investigación de tesis.

Por su parte, el segundo apartado aborda y detalla cada uno de los conceptos necesarios para el logro de los objetivos de tesis, es decir, la construcción, desarrollo e implementación de los módulos que componen el mecanismo híbrido de clasificación de señales EEG-MI (señales electroencefalográficas con intención de movimiento), MHH-FSS-RNA. Entre los conceptos más importantes se tienen: el cerebro y la corteza cerebral, la electroencefalografía, la intención de movimiento, la selección de características, la teoría de testores, el aprendizaje automático, así como modelos de clasificación como las máquinas de soporte vectorial y las redes neuronales artificiales.

En el tercer apartado se describe una propuesta metodológica diseñada en fases que comprende la implementación de los diferentes conceptos definidos en el apartado 2. Así mismo se distinguen las condiciones para las cuales, se realizó el presente reporte de tesis. Por su parte el cuarto apartado, expone los resultados obtenidos por cada una de las fases planteadas en la metodología propuesta. Finalmente, las conclusiones y discusiones son descritas en el quinto apartado considerando distintos puntos de vista.

1.1 Problema

A la fecha existen avances tecnológicos que permiten el estudio del cerebro y sus señales buscando su interpretación utilizando las señales crudas del EEG y así, aplicar métodos matemáticos que permiten interpretar lo que sucede en el cerebro ante distintos estímulos o durante procesos cognitivos [1], [2]. Sin embargo, aún existe el reto en la clasificación precisa y robusta de las actividades neuronales, lo que propicia gran interés por métodos de aprendizaje para la identificación de patrones y relaciones en los registros que permitan un mejor entendimiento y diagnóstico de ciertas patologías [1], [3], así como su aprovechamiento en otras áreas como el control de videojuegos, prótesis, herramientas de comunicación, entre otras.

1.2 Justificación

En la última década se han presentado cambios en la tecnología y la sociedad, especialmente desde 2011 con la introducción del término de la industria 4.0. Dicho concepto trae consigo un nuevo paradigma de integración y digitalización de la tecnología por medio de sistemas inteligentes [4]–[6]. Gracias a ello, la facilidad y el costo de almacenar datos de forma electrónica, así como la capacidad de procesamiento de las computadoras, han propiciado el ambiente ideal para el desarrollo e implementación de nuevas aplicaciones basadas en aprendizaje automático, una rama de la inteligencia artificial, cuyas técnicas permiten a los sistemas aprender de su experiencia y predecir resultados [7]. Este nuevo universo de aplicaciones y tecnologías traen consigo el soporte de la vida cotidiana de los usuarios con nuevas infraestructuras para el acceso a la cultura, la educación, el comercio, los servicios sanitarios y el ocio, por mencionar algunos [4], [8].

La tecnología evolucionó al punto de poseer la capacidad de generar grandes cantidades de información, propiciando la disponibilidad de una incontable cantidad de datos. Por consecuencia, la complejidad de procesamiento aumenta y, por lo tanto, el reto de detectar y explotar las relaciones entre las características del conjunto de datos es mayor [9]. El área de la medicina, por ejemplo, tiene disponibilidad de datos a gran escala y la posibilidad de ser adquiridos e interpretados apropiadamente. Su correcto tratamiento resulta en beneficios como la reducción de costos y tiempos de atención, predicción de epidemias, mejora de esquemas terapéuticos, asesoría y, por supuesto, mejora la calidad de vida [10]. En este escenario se expone la necesidad de herramientas con la capacidad de integrar información, reconocer patrones y la creación de modelos que permitan resolver las limitaciones humanas, disminuir la carga médica, acelerar la atención y ofrecer un mejor servicio con mayor grado de personalización [7]. Sin embargo, de acuerdo con Santiago y Patricio Barzallo en [11] y Álvarez Vega et al. en [7], la medicina apenas se ha prestado al uso de la inteligencia artificial por razones culturales, filosóficas, así como desafíos legales y éticos.

Como se puede observar, la medicina y, específicamente, el cuerpo humano ha sido siempre objeto de estudio [12]. Bajo este hecho es difícil no suponer que el cerebro tiene particular fascinación por parte de la ciencia [12], [13]. El cerebro es uno de los órganos más importantes como unidad de control y de procesamiento de datos del ser vivo, cuyo interés se debe a la complejidad de sus funciones y a los adelantos tecnológicos utilizados para su estudio [12]. Gracias a este particular 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 funcionamiento del cerebro [13]. Gracias a las neurociencias existen herramientas y métodos que permiten encontrar soluciones a patologías y trastornos asociados con el cerebro [14]. Por ejemplo, el electroencefalograma (EEG), un dispositivo capaz de registrar la actividad eléctrica del cerebro y que es utilizado de forma rutinaria [15]. El uso de señales EEG tienen aplicaciones en diferentes dominios, como el diagnóstico,

tratamiento y monitoreo de enfermedades y anomalías relacionadas al cerebro [16], [17] como trastornos compulsivos, evaluación de lesiones, enfermedades degenerativas y alteraciones metabólicas [18]. Sin embargo, no solo la medicina ha sido el objetivo principal de los EEG, también existen avances en otras áreas como la introducción de las interfaces cerebro-computador (BCI, Brain-Computer Interface) [19]. Los BCI permiten la traducción de las señales capturadas para estudios clínicos, rehabilitación, experimentos de respuesta motora e incluso, el desarrollo de tecnologías para la traducción de señales en acciones, comandos de control, nuevas formas de control de videojuegos, nuevos paradigmas de interacción social, entre otros [19]–[21].

No obstante, a pesar de estos avances, aún existen dificultades que restan la eficiencia en su uso [14], [22], siendo uno de ellos la clasificación imprecisa de señales debido a la existencia de interferencia, tejidos intermedios y la alta variabilidad de las señales del cerebro [19], [21]. Por ello, el aprendizaje máquina y la minería de datos, dentro de las ciencias computacionales, representan una perspectiva novedosa para el adecuado procesamiento de señales. De esta manera, se reconocen señales y sus relaciones que propicien un mejor entendimiento y aplicación del conocimiento [23].

1.3 Hipótesis

La implementación de un mecanismo híbrido basado en metaheurísticas que permitirá la clasificación óptima de señales electroencefalográficas de intención de movimiento.

1.4 Objetivos

1.4.1 Objetivo general

Obtener, manipular e interpretar intención de movimiento mediante la clasificación de señales electroencefalográficas usando una metaheurística híbrida en una aplicación práctica.

1.4.2 Objetivos particulares

1. Capturar señales electroencefalográficas (EEG) de intención de movimiento (IM) para su almacenamiento en un repositorio.
2. Aplicar mecanismos de preprocesamiento al conjunto de señales EEG-IM.
3. Realizar el análisis de selección de características de señales EEG-IM por medio de la teoría de testores.
4. Implementar metaheurísticas clásicas para la clasificación de señales EEG con intención de movimiento.
5. Evaluar el desempeño de las metaheurísticas implementadas.
6. Diseñar e implementar un modelo metaheurístico híbrido para la clasificación de las señales EEG-IM.
7. Diseñar e Implementar una aplicación práctica con el sistema metaheurístico híbrido de clasificación diseñado.

Capítulo II

Marco Teórico

En este apartado se abordan brevemente los conceptos utilizados para la elaboración de este trabajo de investigación. La primera parte de esta sección corresponde a la exposición de los antecedentes encontrados en la literatura. Se trata de trabajos relacionados al procesamiento de señales electroencefalográficas y algunas de sus aplicaciones.

La segunda parte expone conceptos que van desde el punto de vista biológico: el cerebro y, específicamente, de la corteza cerebral; hasta elementos técnicos: heurísticas y metaheurísticas, aprendizaje máquina, así como algunos de los clasificadores más conocidos en el área de ciencias computacionales.

2.1 Antecedentes

En la literatura se pueden encontrar avances tecnológicos que han dado origen a diferentes herramientas para la detección y procesamiento de la actividad cerebral tanto para su uso médico como científico [24]. Esto es resultado de múltiples investigaciones para su eficiencia y facilidad de uso [13], entre las cuales se encuentra el procesamiento digital de las señales cerebrales por medio de técnicas de aprendizaje para el apoyo en el análisis de resultados en investigación y diagnóstico médico. Así pues, en este apartado se exponen algunos ejemplos de estas aplicaciones y trabajos de investigación realizados en base a lecturas de señales EEG.

En el primer trabajo revisado, Juan Arriola [25] construye un modelo matemático para la representación de ondas cerebrales en el cual, se analizan señales de un grupo “sano” de control y otro de pacientes que consumen sustancias psicoactivas. Este trabajo de tesis incluyó la automatización de la identificación y clasificación de la información obtenida por medio de la implementación de redes neuronales artificiales. Como resultado se logró clasificar la población en dos clases: sanos y afectados, además de evidenciar las diferencias en la reacción a los estímulos en las pruebas del EEG entre cerebros sanos y cerebros con daño por consumo de sustancias.

La tesis de Escobar y Zurita [20] expone los lineamientos para la construcción de una mano robótica completamente articulada con la capacidad de imitar distintos niveles de agarre de la mano humana. Este mecanismo es controlado por medio de la actividad eléctrica cerebral recibiendo comandos del parpadeo fuerte o débil a través del dispositivo MindWave de NeuroSky.

Por su parte, Santa-Cruz et al. [26] se enfocan en la aplicación de técnicas de aprendizaje a señales obtenidas de un electroencefalograma comercial. En este trabajo se utiliza una base de datos del repositorio de la Universidad de California (UCI) el cual, describe señales EEG por medio de 14 características, correspondientes a los electrodos del dispositivo EEG. Las señales son mediciones correspondientes a dos clases: ojo abierto y ojo cerrado. En este proyecto, los autores realizaron una búsqueda greedy para optimizar los parámetros de los kernel de la librería LIBSVM de MATLAB obteniendo así, mejores resultados en la clasificación.

Por último, el trabajo de Esteban Arango et al. en [27] utiliza una interfaz de realidad aumentada para el tratamiento del síndrome del miembro fantasma en el que se registran las señales del movimiento de una extremidad para simular su movimiento facilitando así, el tratamiento de pacientes que han perdido alguna extremidad.

2.2 Cerebro humano

La mayor parte de los seres vivos tiene la capacidad de realizar acciones consideradas como inteligentes, es decir, llevan a cabo acciones o reacciones adecuadas a su medio ambiente. Los seres humanos han desarrollado procesos intelectuales superiores a los de cualquier otra especie [28], haciendo que uno de los objetivos principales de las neurociencias sea comprender los mecanismos biológicos que permiten tal capacidad [29].

De acuerdo con José Viosca [29], el cerebro es un órgano enigmático pues, a diferencia de otros órganos, su funcionamiento aún se encuentra en la etapa de comprensión. A lo largo de la historia, el cerebro ha sido estudiado desde diferentes áreas del conocimiento como la filosofía, física, anatomía, biología, ingeniería, psicología, y, recientemente por la neurociencia [30]. Se trata de un órgano complejo que pesa cerca de 1,500 gramos y ocupa alrededor de 1,350 cm³ [31], sin embargo, las diferencias en peso no afectan en función e inteligencia [32]. Consta de 100 mil millones de neuronas que utilizan 19 mil genes de los 30 mil que componen el genoma humano las cuales, al conectarse entre sí forman 1,000 millones de conexiones por milímetro cúbico de corteza cerebral.

Todo el sistema se organiza en niveles jerárquicos que dependen unos de otros, como se muestra a continuación:

- ***“Nivel molecular:*** *Implica el ADN de las neuronas, los neurotransmisores y proteínas que propagan el impulso nervioso a través de la sinapsis.*
- ***Nivel celular:*** *Distintos tipos de células cerebrales, sus distintas morfologías y funciones dentro del sistema nervioso.*
- ***Nivel de red neuronal:*** *Las neuronas se agrupan y conectan formando redes neuronales, que se activan para realizar determinadas funciones.*
- ***Nivel funcional:*** *Las redes neuronales se integran en distintas regiones cerebrales, en muchos casos vinculadas a una función específica.*

- **Cognición y comportamiento:** *El cerebro procesa la información sensorial y el movimiento, y gestiona los procesos cognitivos, las emociones y el comportamiento” [29].*

En resumen, el cerebro es el órgano más complejo y misterioso del ser humano, es irremplazable y, al mismo tiempo, responsable del organismo y la comunicación con otros seres vivos. La naturaleza plástica y dinámica permite una constante evolución, especialmente en los seres humanos, dotándolos de habilidades como la lectura y la escritura. Dichas capacidades están relacionadas con la corteza cerebral [29]. A lo largo de este apartado se abordan las secciones cerebrales con mayor relación, tanto para el movimiento real como a la intención de movimiento. Siendo este último el objetivo principal de este reporte de tesis.

Como se podrá observar a lo largo de este apartado, el movimiento no solo proviene de secciones superficiales del cerebro, es decir, zonas corticales. Sino que se involucran elementos internos (subcorticales) que van desde la planeación, la memoria y las sensaciones involucradas en el movimiento real. Incluso, como se menciona en la sección 2.3, son elementos que también pueden implicarse en la intención de movimiento.

2.2.1 Corteza cerebral

Conocido también en la literatura como neocórtex [33], constituye la cubierta externa del cerebro con una superficie aproximada de $2,200\text{cm}^2$ que, a su vez, está conformada por una lámina que contiene alrededor de 60,000 millones de neuronas interconectadas [34]. Este conjunto de neuronas es responsable del procesamiento cognitivo o de la mente consciente. La corteza cerebral es donde terminan las señales sensoriales generadas en el cuerpo humano, las cuales son procesadas en distintos niveles y son integradas para su generación de acciones específicas [35].

En resumen, la corteza cerebral se trata del elemento más desarrollado y complejo del cerebro humano y es responsable del pensamiento, la percepción, el lenguaje, así como la mayor parte del procesamiento de la información [36].

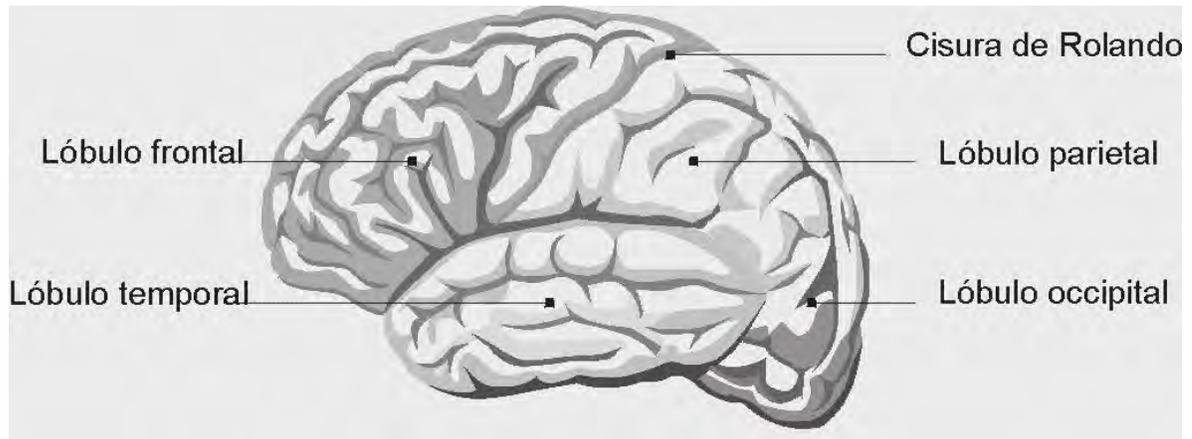


Figura 1. Vista lateral de la corteza cerebral. Obtenida de [34].

La corteza cerebral se organiza en diferentes dominios específicos encargados de diferentes funciones neurológicas, incluyendo las sensoriales y motoras, la visión, audición, el gusto, la memoria y la atención [37]. Como se puede observar en la Figura 1, la corteza cerebral presenta pliegues y pequeñas grietas llamadas cisuras o surcos. Entre este conjunto de cisuras destacan cuatro: la cisura central o de Rolando, la cisura lateral o de Silvio, la cisura parietooccipital y la cisura longitudinal [36]. Estas cisuras permiten el mapeo de la corteza cerebral dividiéndola en cuatro lóbulos: lóbulo frontal, parietal, occipital y temporal [33]. Cada uno de ellos conforman grandes estructuras anatómica y funcionalmente conectadas a nivel subcortical [38].

Lóbulo frontal

Como se muestra en la Figura 2, el lóbulo frontal es una de las estructuras más extensas, pues ocupa un tercio de la superficie de la corteza cerebral [33], [38]. Es el lóbulo con mayor importancia para los seres humanos, pues es responsable de

funciones cognitivas de orden superior como identificar objetos, proyectar metas, establecer planes y controlar y juzgar resultados [31], [33], [39].



Figura 2. Lóbulo frontal. Obtenida de [39].

De acuerdo con Carlos Cuya Mamani en su artículo “El Cerebro Humano, Una Perspectiva Transdisciplinaria” [31], es en el lóbulo frontal donde se encuentra el “alma” de los seres humanos, refiriéndose a que todo lo que denota la personalidad de un individuo reside en este lóbulo. Es aquí donde se encuentran rasgos de conciencia para el juicio, la imaginación, la empatía, la identidad, etc.

El lóbulo frontal se divide en cuatro estructuras: la corteza motora, encargada de la planeación y coordinación del movimiento; la premotora, encargada de la planeación y ejecución del movimientos motrices; la prefrontal, es responsable de funcionamiento cognitivo de alto nivel; y el área de Broca, enfocado en la producción del lenguaje [40].

Como su nombre lo indica, la corteza motora tiene el control de movimientos motores voluntarios o deliberados, además, incluye el lenguaje expresivo y la escritura. Las partes del cuerpo controladas por cada parte de la corteza motora se representa mediante el homúnculo [41]. Este concepto fue creado por el neurocirujano Wilder Penfield y sus colaboradores. El homúnculo (ver Figura 3) se

compone de representaciones humanizadas de los nervios y estructuras cerebrales motoras y sensoriales [42]. Se trata de una figura humana caricaturizada con irregularidad en su morfología, pues el tamaño es proporcional a la información que reciben de sus áreas correspondientes en la corteza motora, es decir, cuanto más intensa y compleja es dicha conexión entre la parte del cuerpo y el cerebro, mayor el tamaño de la sección en la corteza cerebral.



Figura 3. Homúnculo motor y sensorial de Penfield. Obtenida de [42].

La corteza prefrontal es la responsable de la cognición, la conducta y la actividad emocional [31], [38]. Es aquí donde residen las funciones de alto nivel como la toma de decisiones, la resolución de problemas, la inteligencia y la regulación de las emociones. Esta sección del lóbulo frontal se relaciona con desordenes como el déficit de atención e hiperactividad, el autismo, el desorden bipolar, la depresión y la esquizofrenia [40]. Por su parte, el área de Broca es la región del lóbulo frontal asociada con la producción motora del habla y la escritura, así como el procesamiento y comprensión del lenguaje [40], [41].

En resumen, el lóbulo frontal es el responsable de las funciones ejecutivas que determina la conducta humana para resolución de problemas complejos, es decir,

“supervisa y coordina las actividades relacionadas con la inteligencia, atención, memoria, lenguaje, flexibilidad mental, control motor y la regulación de la conducta emocional” [34]. Cada lóbulo controla las operaciones del lado contrario del cuerpo, es decir, el hemisferio izquierdo controla la parte derecha del cuerpo y viceversa [40].

Lóbulo parietal

Ubicado en la zona posterosuperior de la corteza cerebral, entre el lóbulo frontal y el lóbulo occipital, y sobre el lóbulo temporal (Figura 4) [43]. Se asocia principalmente con la sensación y percepción, así como la capacidad de identificar sensaciones corporales, principalmente del campo visual [34], [44], [45].

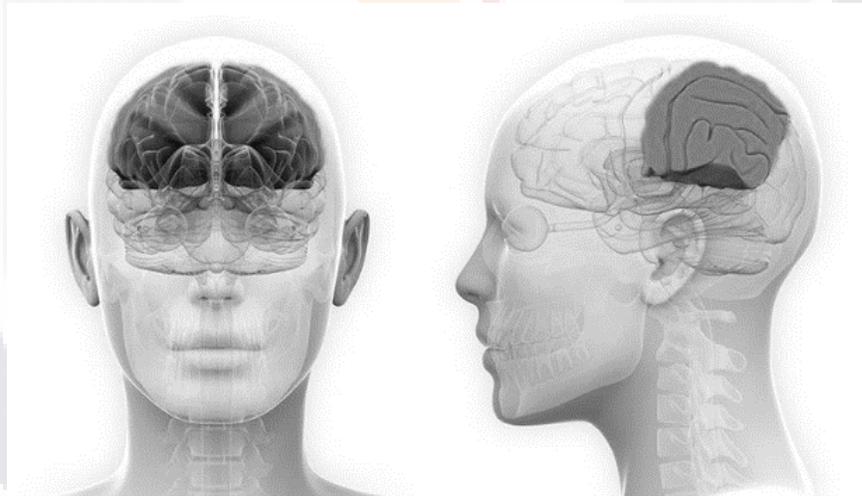


Figura 4. Lóbulo parietal. Obtenida de [44].

El lóbulo parietal recibe las señales de los receptores de la piel, articulaciones, músculos y vísceras, para ser procesadas y, así, permitir sensaciones de dolor, vibración, tacto, presión, posición y movimiento [33], [34]. Su importancia, radica en la integración de la información de los sentidos del cuerpo para construir una imagen coherente del mundo alrededor [43].

El lóbulo parietal también dispone, aunque de forma limitada, de competencias motoras para la ejecución de movimientos gruesos como el movimiento de brazos,

piernas, pies y de cuerpo completo [33]. Además, de permitir movimientos precisos en el espacio encargándose de la percepción espacial del cuerpo y de los objetos a su alrededor [34]. Entre otras funciones asociadas, se encuentra la coordinación del movimiento, la lectura, la escritura, la intervención en procesos de memoria sensorial de corto plazo, así como en procesos de operaciones numéricas al producir la integración sensorial de la información necesaria para la realización de cálculos aritméticos [34], [43], [44].

La estructura del lóbulo parietal se divide en la corteza somatosensorial, el lóbulo parietal inferior, el lóbulo parietal superior y el precuneo [43]. Iniciando con la corteza somatosensorial, se trata de la sección del lóbulo parietal encargada de la recepción y procesamiento de la información sensorial de todo el cuerpo (p.ej. tacto, temperatura y dolor) [43]. Dicha información llega a través de la médula espinal y se mapea en el cerebro en la corteza somatosensorial, es decir, en el homúnculo sensorial (ver Figura 3) de Penfield [45], lo que permite la localización de la sensaciones [43].

En cambio, el lóbulo parietal superior es asociado principalmente, a los movimiento planificados, la orientación espacial y la atención [45]. Además, se encarga de la integración sensoriomotora, señales visuales y sensoriales de las manos [43]. Por su parte, el lóbulo parietal superior, se involucra en el lenguaje, operaciones matemáticas, la imagen corporal, la atención espacial, el procesamiento auditivo, la percepción de emociones a través de expresiones faciales, el aprendizaje y la esterognosia, es decir, la capacidad de diferenciar objetos según su tamaño, forma, peso, etc. [32], [43].

Por último, el precuneo es una de las áreas de las que se cuenta con un mapeo de menor precisión. Sin embargo, se asocia a las imágenes visoespaciales, la memoria episódica, las operaciones de autoconocimiento y la conciencia corporal en general, así como la capacidad de adoptar perspectivas en primera persona y el sentido de la autoconciencia [43], [46].

En resumen, el lóbulo parietal recibe e interpreta señales de otras partes del cerebro. Integra entradas sensoriales lo que permite a las personas comprender su entorno y el estado del cuerpo. Así, el lóbulo parietal permite darle sentido al entorno en el que se encuentra [47].

Lóbulo temporal

El lóbulo temporal es uno de los componentes de la corteza cerebral mejor comprendidos, ocupa alrededor del 20% del volumen neocortical [48]. El nombre de “temporal” se refiere a las sienes de la cabeza, en relación a su posición en el cerebro [49] como se puede observar en la Figura 5. Su rol principal incluye la percepción auditiva responsable de la interpretación de sonidos lingüísticos, musicales, entre otros; colaboraciones importantes de percepción visual; reconocimiento de caras y objetos; además de una importante contribución a funciones psicológicas como la experiencia afectiva, emocional y personal [33], [34], [50].

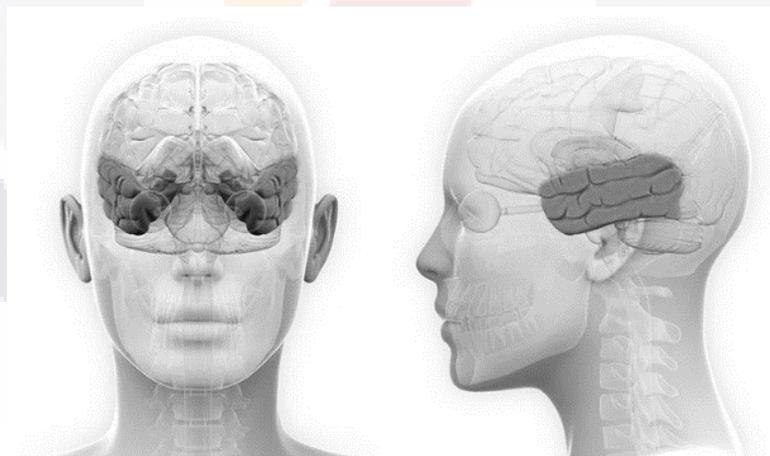


Figura 5. Lóbulo temporal. Obtenida de [50].

De acuerdo con Portellano [34], el lóbulo temporal es responsable de tareas asociadas con la memoria, el lenguaje comprensivo y la regulación emocional. El lóbulo temporal posee estructuras que son los principales centros de registro

mnémico que permiten el almacenamiento de información a corto plazo, consolidando la memoria.

Al igual que los demás lóbulos, existe un lóbulo temporal en cada hemisferio del cerebro que difieren en sí mismos. El lóbulo temporal izquierdo o área de Wernicke, el más dominante, se asocia con la comprensión del lenguaje, el aprendizaje, la memorización, el habla y el recuerdo de información verbal. Mientras que el lóbulo temporal derecho se encarga del aprendizaje y memorización de información no verbal, como dibujos o música; el reconocimiento de información; el reconocimiento de expresiones faciales; la distinción de entonaciones del lenguaje; y el procesamiento de estímulos auditivos no verbales como la música [34], [49].

El lóbulo temporal se divide en subestructuras con funciones especializadas. La primera de ellas es el gyrus superior temporal asociado con el procesamiento auditivo y de lenguaje, la cognición social, la percepción de emociones desde las expresiones faciales. La corteza auditiva analiza, como su nombre lo indica, información auditiva procedente de los oídos, especialmente en procesamiento de la semántica en el lenguaje y la visión. Por su parte, el sistema límbico es un grupo de estructuras en lo profundo del cerebro encargadas del procesamiento y regulación de la memoria, para la transición a la memoria permanente; el procesamiento de emociones, el miedo y la recompensa, así como la respuesta de lucha y huida [34]. El área de Wernicke forma parte del lóbulo temporal izquierdo y se vincula con el desarrollo del lenguaje y la comprensión del habla y la palabra escrita [49].

En resumen, los lóbulos parietales son importantes en el reconocimiento de palabras y lugares, personas, la interpretación del lenguaje y las emociones de otras personas [47]. El daño en los lóbulos parietales puede provocar caminata inestable, la incapacidad de reconocer rostros, alucinaciones (visuales, auditivas y olfativas), apatía, sordera y la pérdida de memoria a corto y largo plazo, por mencionar algunos [49].

Lóbulo occipital

Como se observa en la Figura 6, el lóbulo occipital se ubica en la parte posterior del cráneo [34], [51] y ocupa un volumen del 12% del total neocortical [52]. Su principal función se relaciona con el procesamiento de información visuoespacial, la percepción de distancia y profundidad, el color, el reconocimiento de objetos y rostros, así como la formación de la memoria [34], [47], [53].

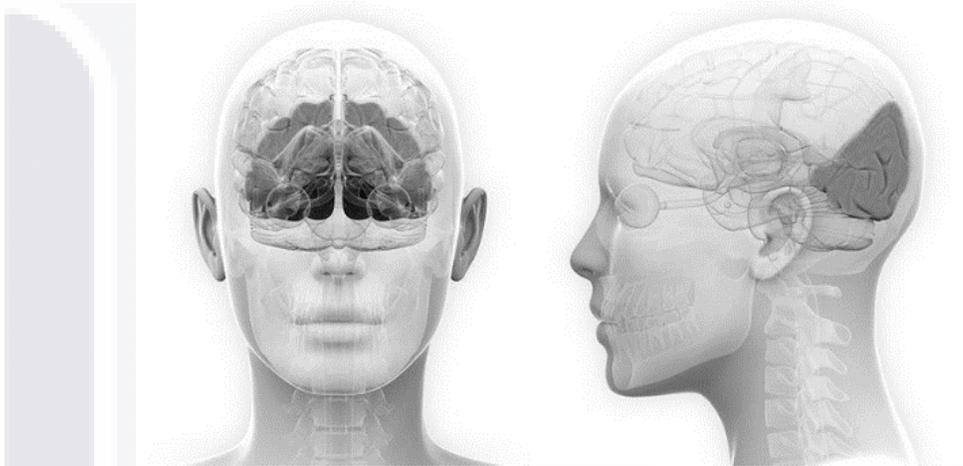


Figura 6. Lóbulo Occipital. Obtenida de [51].

Los lóbulos occipitales se involucran en diferentes funciones debido a su capacidad de recibir información de otras regiones del cerebro. Por ejemplo, son capaces de transmitir información a los lóbulos temporales con el objetivo de dar significado a la información visual, almacenar recuerdos y responder a estímulos externos [54].

Al igual que el resto de los lóbulos, los lóbulos occipitales pueden ser divididos en distintas áreas funcionales [32], [54]. La corteza visual primaria (área 17 de Brodmann o área visual V1) recibe información sensorial de los ojos a través del tálamo, para luego transmitir información de ubicación, datos espaciales, movimiento y colores de los objetos en el campo de visión [53], [54]. La corteza visual secundaria (área visual V2 o área de Brodmann 18 y 19) recibe información de la corteza visual primaria y su importancia radica en la percepción del color, el

movimiento y la profundidad [52], [54]. Por su parte, la corriente ventral es la encargada del flujo de la información hacia el lóbulo temporal para procesar el significado de los objetos observados. El cuerpo geniculado lateral forma parte del tálamo y, como se mencionó anteriormente, actúa como sistema de transmisión sensorial antes de recibirse en la corteza visual primaria. La língula, en conjunto con el cuerpo geniculado lateral, crea conciencia espacial y profundidad a la información visual. Finalmente, la corriente dorsal permite el procesamiento de dónde se encuentran los objetos [54].

Las lesiones del lóbulo occipital se relacionan con la discapacidad visual, alucinaciones, dificultades de localización, de percepción de profundidad, de identificación de colores, de lectura y escritura; así como la incapacidad de ver colores y de reconocer objetos dibujados [52], [54].

2.2.2 Ganglios basales

Los ganglios basales se refieren a un grupo de núcleos subcorticales asociados al control motor y las funciones ejecutivas, como el aprendizaje motriz, el control del comportamiento y las emociones [55], [56].

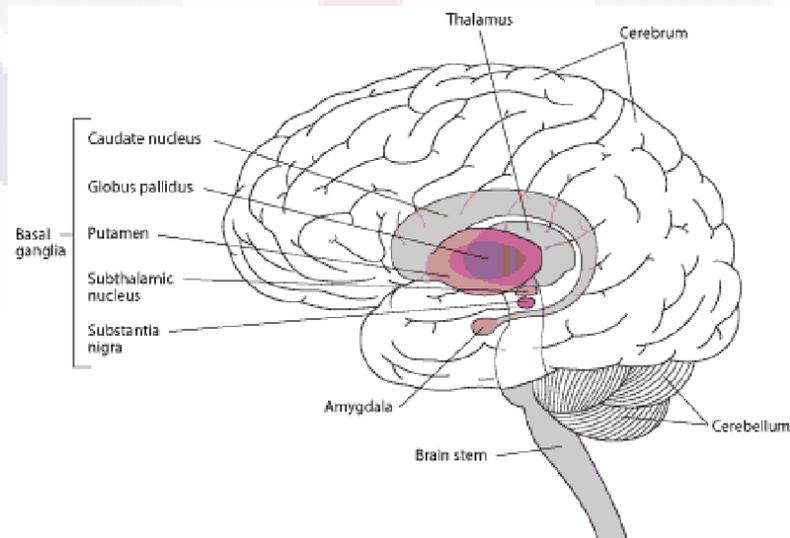


Figura 7. Ganglios o núcleos basales. Obtenida de [57].

Como se muestra en la Figura 7, los ganglios basales se ubican en la parte más interna del cerebro y conforman parte de las estructuras más primitivas del cerebro humano que trabajan en conjunto con el resto del sistema nervioso [58]. Estas estructuras poseen interconexiones entre ellas y con otras áreas cerebrales como la corteza parietal, el sistema límbico, la corteza frontal, el cerebelo, el hipotálamo y con los circuitos oculomotores [59]. De esta manera resulta en su influencia en funciones relacionadas al movimiento voluntario, su planificación, integración y control como la postura corporal o el movimiento de las extremidades; el aprendizaje procedimental, asociando con actividades que requieren de práctica como la conducción; la conducta emocional y motivacional, trabajo realizado en conjunto con el sistema límbico y el sistema de recompensa cerebral; la coordinación del movimiento ocular; y la orientación del cuerpo en el espacio [58], [59].

Los ganglios basales se conforman de estructuras como el cuerpo estriado, el núcleo caudado, el putamen, el globus pallidus y sustancia negra [55], [58], cuyas funciones específicas se enlistan a continuación:

- **El cuerpo estriado**, también conocido como núcleo estriado o neostriado es la estructura de los ganglios basales con mayor recepción de información [42], [60]. Engloba la mayor parte del área de los ganglios basales y se compone del núcleo caudado y el putamen [55], [60]. Sus funciones se enfocan a funciones motrices como el aprendizaje motor, procesamiento de memoria procedimental, la regulación de movimientos voluntarios (dirección, intensidad y amplitud), la ejecución de movimientos automáticos, movimientos oculares, regulación de memoria de trabajo, focalización de la atención, regulación de la conducta motivada (en función de la dopamina) y la selección de acciones en función de la recompensa [60].
- **El núcleo caudado** que forma parte del cuerpo estriado y constituye un elemento importante vinculado al control de movimiento [61], específicamente con la postura del cuerpo y las extremidades, la velocidad y precisión de los movimientos. Así mismo, el núcleo caudado

se involucra en tareas de memoria y aprendizaje, la comprensión de estímulos auditivos (incluyendo los propios del lenguaje), la sensación de alarma y la motivación, al tratarse de una estructura que conecta el sistema límbico con la corteza frontal [55], [61].

- **El putamen** se constituye de materia gris y se asocia principalmente con el movimiento facial y de las extremidades [58]. Se relaciona, además, con la selección de movimientos, la regulación del aprendizaje motor y la planificación de secuencias de movimientos motrices [62]. Asimismo, también se relaciona con el condicionamiento de la conducta (refuerzo y castigo), el aprendizaje, así como en la sensación de asco y desprecio, gracias a su conexión con la ínsula [55], [58], [62].
- **El globo pálido**, globus pallidus o paleoestriado [55], [58]. Se trata de una estructura dentro de los ganglios basales cuya principal función se relaciona con la regulación de movimiento no consciente, modulando impulsos excitatorios del cerebelo [55], [63]. En este mismo sentido, en conjunto con el cerebelo, el globo pálido permite el mantenimiento de la postura y el control de movimiento [63].
- **La sustancia negra** se relaciona con la dopamina en actividades relacionadas con la recompensa y las sensaciones placenteras. Donde la sustancia negra hace una integración de estímulos y reacciones provocando la repetición de cierto patrón de comportamiento [55], [64]. En cuanto al movimiento motriz, la sustancia negra se involucra específicamente en la iniciación y control de movimientos finos. En otros contextos, la sustancia negra comprende funciones como el aprendizaje espacial, la percepción del tiempo, los movimientos oculares y la regulación del sueño, especialmente en la fase REM [64].

Finalmente, una lesión en los ganglios basales se relaciona, generalmente, a problemas relacionados al movimiento (problemas hipo o hipercinéticos) [58]. El más común de los trastornos relacionados a los ganglios basales es la enfermedad de Parkinson y describe síntomas de bradicinesia, temblor y rigidez [55], [56], [58].

Debido a su relación con la motivación personal, una lesión en los ganglios basales puede provocar el síndrome de pérdida de auto activación psíquica, la cual se refiere a la pérdida de la capacidad de interesarse, la espontaneidad y la motivación [58]. El síndrome de Tourette también se relaciona a estas estructuras subcorticales y se distingue cuando el paciente presenta movimientos, vocalizaciones o gestos de forma inconsciente [58], [65]. Asimismo, los ganglios basales se relacionan, además, con problemas psicológicos como el trastorno obsesivo compulsivo (TOC) o el trastorno de déficit de atención e hiperactividad (TDAH) [58].

2.2.3 Cerebelo

Como se ha mencionado anteriormente, los movimientos voluntarios e involuntarios se basan en patrones espaciales y temporales de contracciones musculares, iniciados y coordinados por diferentes estructuras del sistema nervioso central. En el caso del aprendizaje y mantenimiento de movimientos hábiles se involucran zonas del cerebro como la corteza cerebral, los ganglios basales y, por supuesto, el cerebelo [65].

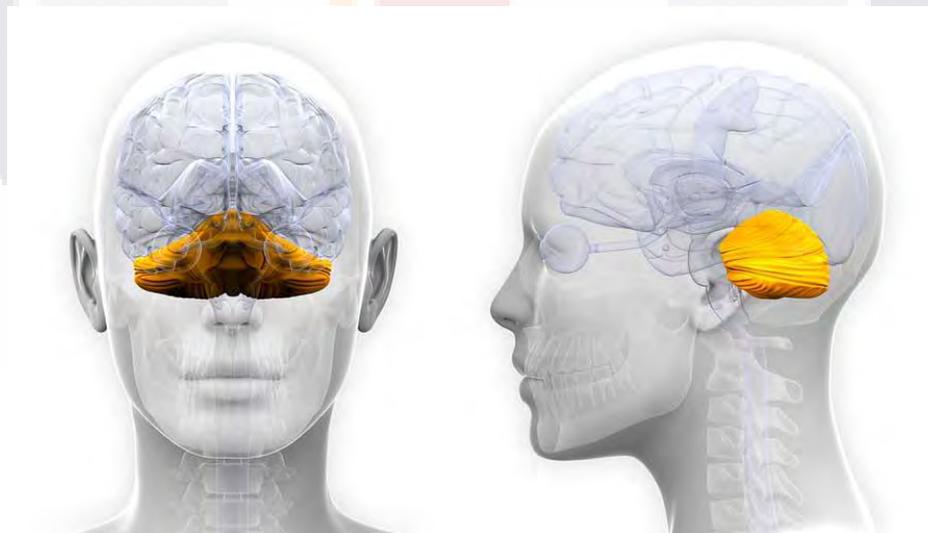


Figura 8. Cerebelo. Obtenida de [66].

De acuerdo con la Figura 8, el cerebelo (“pequeño cerebro”) es una estructura cerebral [67] que representa el 10% de la masa total del cerebro y posee alrededor del 80% de las neuronas en el cerebro [68]. Se localiza detrás de la parte superior del tronco encefálico, el lugar donde conecta la médula espinal y el cerebro, debajo de los lóbulos occipital y temporal [66], [69], [70].

En la literatura, el cerebelo es asociado generalmente con la coordinación motora de movimientos voluntarios e involuntarios [65], [70], [71] gracias a su conexión con las áreas motoras y premotoras [72]. Sin embargo, existen estudios en los que se relaciona al cerebelo con procesos cognitivos como el razonamiento espacial, el lenguaje, la memoria de trabajo y la toma de decisiones [71], [73].

En cuanto a los movimientos intencionales, estos inician esencialmente en la corteza motora para ser procesados por varios centros corticales y subcorticales como los ganglios basales (ver sección 2.2.2) y el cerebelo. En este punto, estas estructuras, influyen a la corteza motora para dar forma a la señal del movimiento antes de transmitirse a la médula espinal y proyectarse en los músculos [65]. Esto es, el cerebelo no inicia el movimiento, éste, recibe la información de los lóbulos frontales y sabe el movimiento a realizar para después, encargarse de organizarlo y asegurarse de la correcta coordinación y fluidez [70]. Además, el cerebelo recibe información sensorial desde el tronco encefálico, la médula espinal y el cerebro, por lo que conoce la posición del cuerpo y la actividad que está realizando cada parte de éste. De manera que el cerebelo toma parte, además, en el equilibrio y la postura del cuerpo [69], [70], [74].

Así, los ganglios basales y el cerebelo son imprescindibles en la organización, coordinación, sincronización y secuenciación de un movimiento motriz normal. Asimismo, el cerebelo se relaciona con procesos del aprendizaje motor [65], [75], es decir, movimientos que requieren de práctica y afinación como andar en bicicleta o tocar un instrumento musical [68], [70].

Como se señaló anteriormente, el cerebelo no solo está incluido en el control de movimiento. Pues posee conexiones con el sistema límbico, el cual, se asocia

principalmente con estados emocionales. Por lo tanto, el cerebelo es partícipe en la regulación de emociones creando asociaciones entre sensaciones y sentimientos. De esta manera, relaciona experiencias con sentimientos concretos [69].

El cerebelo también ha sido estudiado bajo el contexto de roles cognitivos, idea que ha sido discutida desde mediados del siglo XIX [76], teniendo un incremento en el interés del rol del cerebelo en la emoción y cognición [77]. A inicios de los años 80, se reafirma la idea sobre la relación la influencia del cerebelo y la cognición [78]. Pues los avances tecnológicos en neuroimagen y el desarrollo de modelos computacionales han demostrado el rol del cerebelo en funciones motrices y no motrices [77].

El cerebelo posee un canal de salida que cuenta con proyecciones hacia áreas de asociación cerebral, incluyendo la corteza prefrontal [78]. Como recordará el lector, en la sección 2.2.1 se hace mención de que la corteza prefrontal es responsable de la cognición, la conducta y la actividad emocional, es decir, es responsable de funciones de alto nivel como la toma de decisiones, la resolución de problemas, la inteligencia y la regulación de las emociones [31], [38], [40]. En la actualidad, se continua con la exploración sobre la influencia del cerebelo en el pensamiento, el procesamiento del lenguaje y estado de ánimo [68].

Buckner [78] hace mención del trabajo de Ito [79] en el que se sugiere que el papel del cerebelo en la función cognitiva es paralelo a su función en el control de movimiento. En esta teoría, el cerebelo crea modelos internos de los movimientos a través de la repetición y la retroalimentación. De la misma manera, los procesos cognitivos (escenas imaginadas y pensamientos contruidos) son operados por mecanismos de retroalimentación y modelos internos influenciados por el cerebelo. En este mismo trabajo, Buckner hace mención de que el cerebelo realiza vínculos con unidades cognitivas del pensamiento durante la coordinación y sincronización del movimiento.

En resumen, el cerebelo es una estructura compleja con conexiones específicas de alimentación y retroalimentación con la corteza cerebral. Estas conexiones

permiten el control del movimiento motor al relacionarse con áreas corticales motoras y premotoras. Sin embargo, también existen conexiones con las cortezas paralímbicas y de asociación. De esta manera, el cerebelo realiza una transformación universal aplicable al dominio motor, cognitivo y afectivo. El cerebelo es encargado del control motor, la memoria de trabajo, el lenguaje, el control de emociones, el razonamiento abstracto y la resolución de problemas [70], [72], [78].

2.2.4 Neurona biológica

Hasta el momento, se ha abordado el concepto de “cerebro” como un sistema complejo compuesto células conocidas como neuronas que poseen muchas características que comparten con las células del resto del cuerpo [80]. Sin embargo, son *“excepcionales por su impresionante diversidad, por la complejidad de sus formas y su intrincada red que comunica a unas células con otras”* [81].

La neurona supone una unidad fundamental y estructural del cerebro y el sistema nervioso. Se trata de una célula especializada que conduce impulsos electroquímicos responsables de recibir información sensorial a lo largo del cuerpo para controlar, modular e integrar funciones de los tejidos en el cuerpo humano [82], [83]. Las neuronas son responsables de la capacidad de pensar, moverse, sentir y recordar. Se trata de *“procesadores biológicos únicos que codifican, transmiten y computan la información necesaria para la realización de funciones por medio de impulsos eléctricos”* [29].

El cerebro consta con alrededor de 100 mil millones de neuronas y se conectan entre sí formando mil millones de conexiones por milímetro cúbico de corteza cerebral. En la conexión neuronal existe un pequeño espacio conocido como sinapsis cuya función es esencial para el correcto funcionamiento de las redes neuronales [29], [81].

Como se mencionó, las neuronas se comunican entre sí a través de sus prolongaciones formando unidades funcionales llamadas sinapsis [83]. La sinapsis

permite que los impulsos nerviosos viajen por las redes neuronales, que tienen como meta la ejecución de una respuesta final [84], [85]. En esencia, la sinapsis consiste en una descarga química transformada o traducida en una señal eléctrica que viaja a través de las redes neuronales en el cerebro a alta velocidad [85], [86]. La sinapsis se puede llevar a cabo entre neuronas (células nerviosas), conocida como transmisión sináptica; o entre neuronas y una glándula o una célula muscular, denominada unión neuromuscular [87].

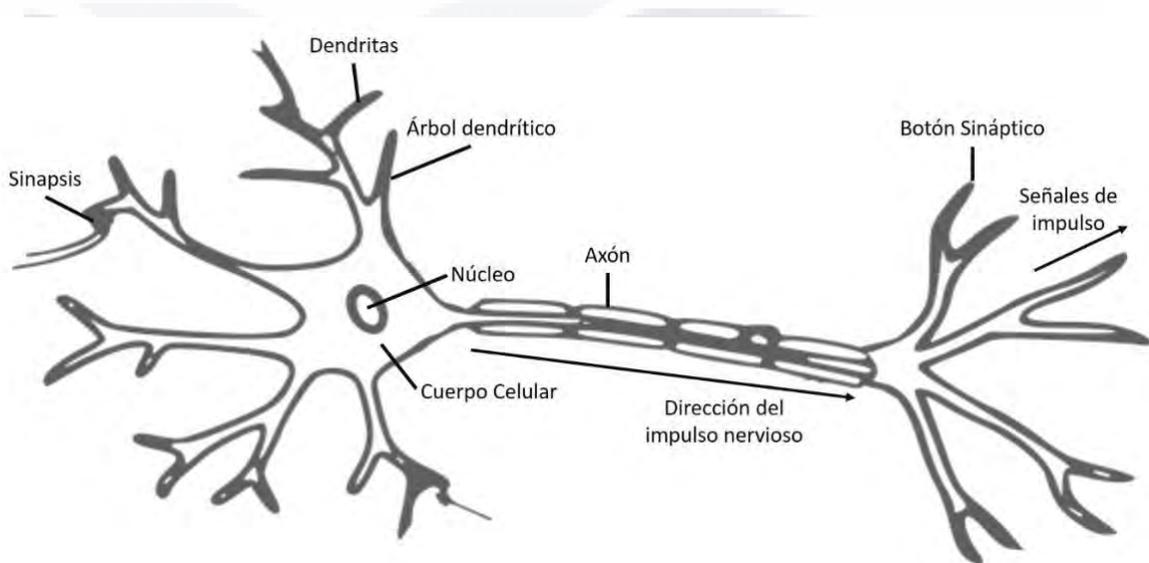


Figura 9. Composición de la neurona biológica. Imagen basada en los trabajos de [29], [86], [88].

Como se muestra en la Figura 9, la neurona tiene forma estrellada conformada en tres elementos: el soma o cuerpo celular, las dendritas y el axón [82]. El soma, también conocido como cuerpo celular, es donde se encuentra el núcleo celular y otros organelos (orgánulos) dentro de la membrana citoplasmática. El soma se considera el centro de operaciones de la célula [80], [89] al ser el área de la célula encargada de la síntesis de neurotransmisores [83].

Del cuerpo celular se proyectan extensiones con pequeñas ramificaciones (árbol dendrítico) conocidas como dendritas [90] (ver Figura 9). Las dendritas son las encargadas de la recepción de información proveniente de otras neuronas a través

de la sinapsis. Es decir, son las responsables de formar conexiones especializadas con otras neuronas para el intercambio y procesamiento de información [83]. Las dendritas convierten la señal en pequeños impulsos eléctricos y transmitiéndolos al soma, por lo que terminan siendo críticas en la integración de la señal y en el grado en que la neurona produce potenciales de acción [80], [83], [89].

El axón es la extensión más larga de la célula que se encargada de la transmisión de información a otras células [80], [82]. Es decir, es la zona de la neurona especializada en la conducción de los potenciales de acción. Se trata de una proyección única que puede extenderse hasta cientos de veces el diámetro del cuerpo celular [89].

De acuerdo con lo anterior, es posible rescatar tres funciones principales de la neurona. La primera de ellas es la recepción de información por parte de las dendritas en la neurona. La segunda función consiste en la integración de la información en el soma, donde se determina si se realiza un potencial de acción. Por último, la tercera función consiste en la transmisión de la información a músculos, glándulas u otras neuronas, por medio del axón. Así, el funcionamiento del sistema nervioso depende de los conjunto de neuronas que se inhiben o estimulan entre sí formando circuitos para procesar información de entrada y producir una salida [90].

2.3 Intención de movimiento

La intención de movimiento (motor imagery, MI), imaginación motora o práctica mental de movimiento [91], es una herramienta de la mente humana que le permite recordar o anticipar movimientos, haciendo posible simular las consecuencias de un movimiento en el entorno sin la necesidad de interactuar físicamente con él [92]. Los trabajos de Mokienko et al.[93], Ruffino et al. [94], Dickstein y Deutsch [95], y Pilgramm et al. [96], coinciden en que la intención de movimiento es la representación mental de movimiento desde una perspectiva personal sin algún movimiento muscular. La intención de movimiento “es un proceso en el que el participante recuerda las representaciones sensoriomotoras que son ejecutadas durante la ejecución real del movimiento” [94] (ver Figura 10).

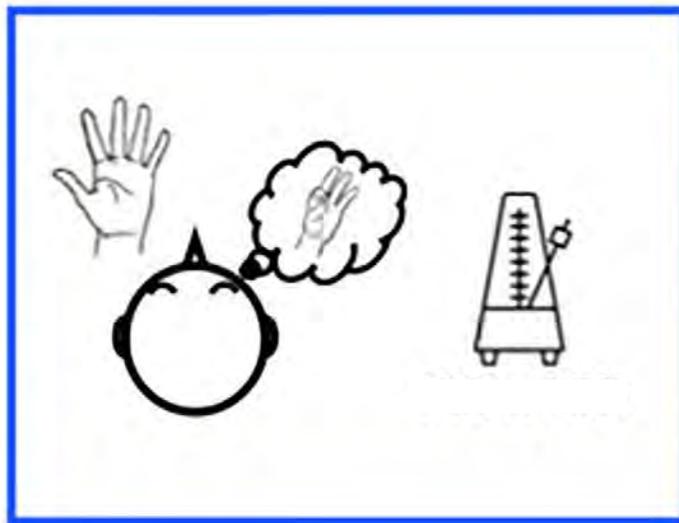


Figura 10. Intención de movimiento. Obtenida de [97].

En la literatura se distinguen dos tipos de intención de movimiento: las formas visuales y las formas cinestésicas de imágenes motrices [93]. En la forma visual, el sujeto produce una imagen de su movimiento simulando verse a sí mismo en tercera persona. Mientras que, en la forma cinestésica el sujeto genera la sensación

cinestésica del movimiento, es decir, la representación del movimiento en primera persona.

Desde el punto de vista médico, la intención de movimiento ha tenido resultados positivos en la rehabilitación de pacientes con condiciones neuromusculares como accidentes cerebrovasculares, lesiones medulares y la enfermedad de Parkinson [95]; así como la prevención del deterioro de la movilidad en adultos mayores [98]. Por ejemplo, en pacientes con accidentes cerebrovasculares la intención de movimiento 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 [95]. En la práctica deportiva, el uso de intención de movimiento ha mostrado efectos positivos en el rendimiento motor y el entrenamiento en deportes profesionales como natación, golf, gimnasia y windsurfing [99].

Además del ámbito deportivo y la rehabilitación, las investigaciones sobre intención de movimiento también se relacionan con la ingeniería. Las ciencias computacionales han abordado la intención de movimiento para el desarrollo de interfaces cerebro-computadora (BCI) por medio de la captura de señales de intención de movimiento utilizando técnicas de electroencefalografía (ver sección 2.4) [100]. Como su nombre lo indica, este tipo de sistemas permiten la interacción cerebro-máquina traduciendo el pensamiento en comandos para un dispositivo externo [100] para llevar a cabo tareas específicas proporcionando una nueva alternativa a la comunicación no muscular [101].

Los sistemas BCI basados en intención de movimiento 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 intención de movimiento 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 [100], [101].

2.3.1 Bases neurofuncionales

La práctica de intención de movimiento representa una operación cognitiva (interna, consciente y auto intencionada [96]) que desencadena procesos sensoriales y perceptivos que activan acciones motrices específicas dentro de la memoria de trabajo [95]. Es decir, la intención de movimiento “*representa una emulación de un estado interno de preparación de la acción*” [102]. Esto significa que la práctica de intención de movimiento requiere de la activación consciente de casi las mismas áreas neocorticales involucradas en la preparación y ejecución de práctica física (ver Figura 11) [102], [103] (p.ej. el área motora suplementaria medial, las cortezas premotora y primaria, corteza prefrontal dorsolateral, la corteza parietal posterior, los ganglios basales, el cerebelo e, incluso, la médula espinal [92], [104]). Por lo que permite el desarrollo motor y aprendizaje de habilidades motrices (especialmente MI cinestésica) evidenciando incluso, ganancia de fuerza en grupos musculares específicos [95], [98], [102], [105]. Lo que demuestra la estrecha relación entre la representación mental por intención de movimiento y la mejora y recuperación de movimientos físicos complejos [99], [106].

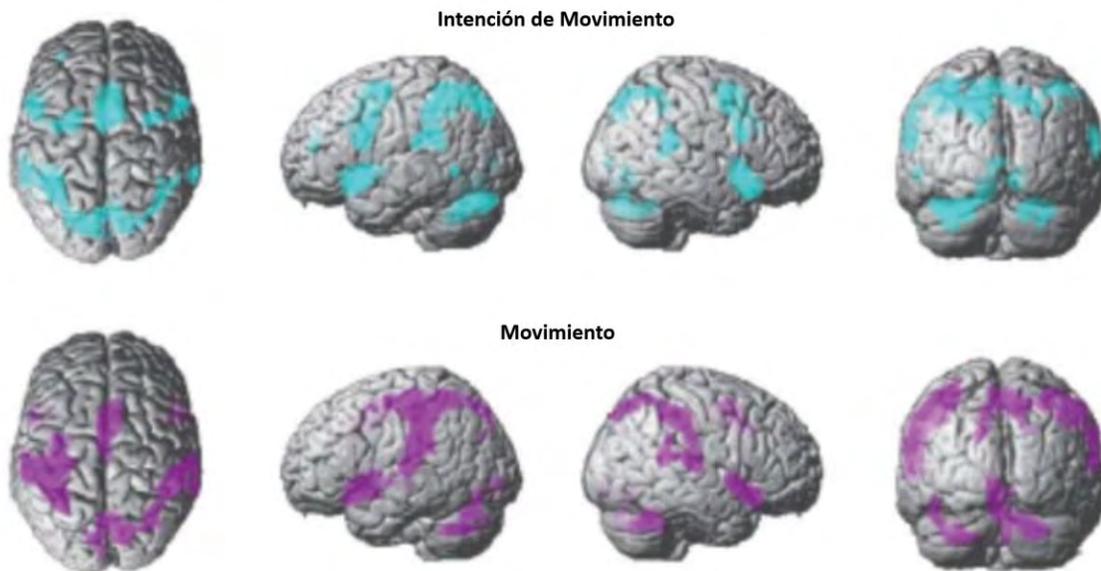


Figura 11. Muestras de fMRI durante intención de movimiento y práctica física de tareas con miembro superior. Obtenida de [102].

Como se mencionó anteriormente, existe evidencia de la equivalencia neurofuncional entre la intención de movimiento y la práctica física, sin embargo, los patrones de activación no son estrictamente idénticos [102]. La Figura 11 ilustra muestras de imágenes de resonancia magnética funcional (fMRI), donde se puede observar la existencia de superposiciones de ciertas regiones cerebrales activas. Este hecho también es sustentado por el trabajo de Guillot et al [103], donde se sostiene que la intención de movimiento requiere de la activación de prácticamente, la misma red neuronal de percepción y control motor utilizados en la práctica física. Esto, debido a que la intención representa una emulación de un estado interno de preparación de la acción [102], [106].

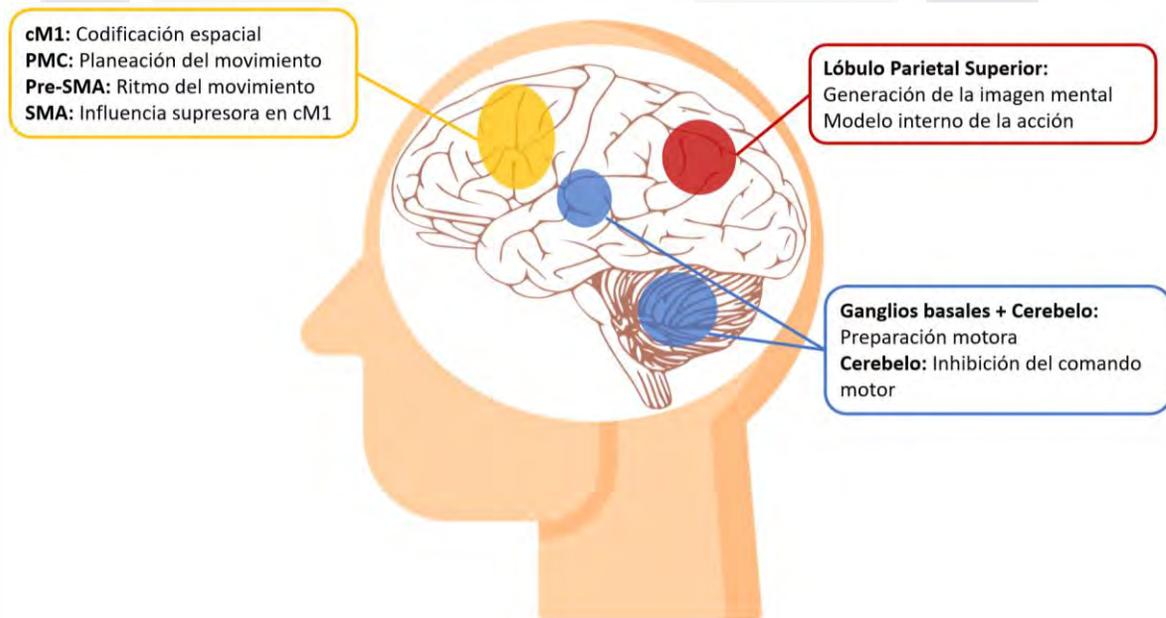


Figura 12. Esquematación de la actividad cerebral durante la intención de movimiento.
 Traducción y adaptación del original publicado en [103].

La Figuras 12 muestra las principales áreas de activación en la corteza cerebral durante la intención de movimiento. Entre las áreas más reportadas como activas se encuentra la corteza frontal, corteza motora primaria (M1), el área motora suplementaria (SMA), pre-SMA; la corteza premotora (PMC); la corteza parietal, la región parietal superior (SPL) e inferior (IPL); la corteza prefrontal (PFC) [96]; así

como regiones subcorticales como los ganglios basales y el cerebelo [103], [106]. Sin embargo, es importante señalar que la activación de zonas cerebrales puede variar dependiendo del tipo de intención de movimiento aplicado. Recordando que existe la intención visual de movimiento, donde la persona se visualiza realizando un movimiento específico (en tercera persona); mientras que la intención de movimiento cinestésica la persona imagina los sentimientos y sensaciones producidas por el movimiento, es decir, el “cómo se siente” al realizar el movimiento [107]. La Figura 13, publicada por Guillot et al. [103], muestra las distintas zonas cerebrales activadas según el tipo de intención de movimiento obtenidas por estudios de fMRI (imagen por resonancia magnética funcional). En color azul corresponden a las zonas activadas por intención de movimiento cinestésico mencionadas al principio del párrafo y representan el objetivo del presente trabajo. Mientras que el color rojo denota las zonas activas por intención visual de movimiento, entre las que se encuentran las regiones occipitales (áreas visuales) y el lóbulo parietal superior [102].



Figura 13. Zonas cerebrales específicas activadas durante intención de movimiento visual (rojo) y cinestésico (azul). Obtenida de [102], [103].

La arquitectura del funcionamiento de intención de movimiento se describe a continuación.

En la corteza frontal: la corteza motora primaria o primary motor cortex (M1) (ver Figura 14) es ampliamente reportada en la literatura como activa durante ejecución de intención de movimiento, especialmente en su forma cinestésica [102]. M1 es subdividido en múltiples secciones, donde cada una es responsable en el control de diferentes áreas del cuerpo, incluyendo el homúnculo cortical (sección 2.2.1) [107]. De manera general, M1 es relacionada con el control de movimientos voluntarios en un orden superior (p.ej. la dirección del movimiento la posición objetivo y el objetivo del movimiento) [96]. Su activación suele ser menor que en la ejecución real del movimiento, sin embargo, se ha encontrado que su activación está estrechamente relacionada con la complejidad del movimiento estudiado. Es decir, a mayor complejidad, mayor activación [103].

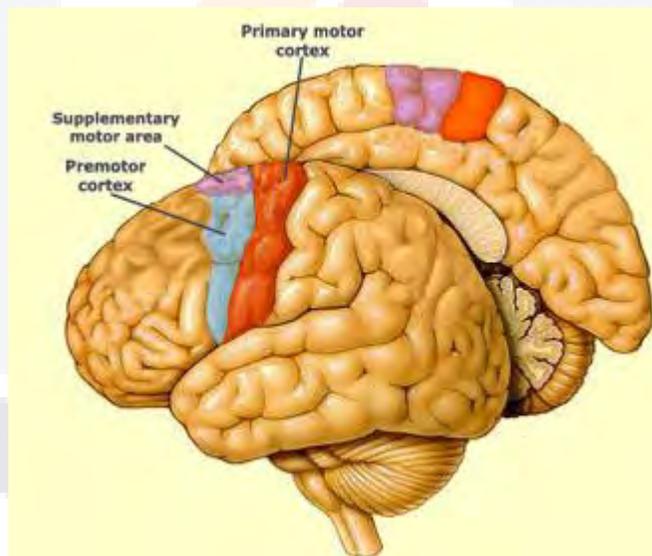


Figura 14. Áreas de la corteza frontal involucradas en intención de movimiento. Obtenida de [108].

El área motora suplementaria o supplementary motor area (SMA) (ver Figura 14) tiene mayor aceptación en cuanto a su participación en intención de movimiento. Esta sección de la corteza cerebral controla la planificación de acciones motoras

[103]. SMA es crucial en la programación y simulación de complejas secuencias motrices [109], así como en la inhibición de M1 previniendo la contracción muscular, durante la intención de movimiento [102], [103], [110].

La corteza premotora o premotor cortex (PM) (ver Figura 14) posee una actividad robusta durante la intención de movimiento en su parte dorsal la cual, se involucra en la preparación y el control del movimiento antes de realizar la simulación. Mientras que la parte ventral se relaciona estrechamente con la planificación de los movimientos. Su influencia se debe, particularmente, a la presencia de las neuronas espejo que se activan durante la imitación y el reconocimiento de acciones [102], [103], [110], [111].

En la corteza parietal: se reportan áreas como la corteza somatosensorial y, especialmente los lóbulos parietales superior e inferior, así como el precuneo [103]. Fleming et al. [112] reportan que tanto la zona parietal izquierda como parietal derecha presentan un mayor nivel de dependiente de nivel de oxígeno en la sangre (BOLD) durante la intención de movimiento que en la ejecución motriz. Específicamente, el lóbulo parietal inferior y la corteza somatosensorial tienen mayor activación cuando se trabaja con intención de movimiento cinestésica, mientras que, el lóbulo parietal superior tiende a mayor activación cuando la persona posee mayor experiencia en el movimiento analizado. Finalmente, el precuneo posee mayor relación con la intención visual de movimiento, es decir, la visualización en tercera persona [103]; así como en secuencias de acción bimanual que dependen de recordar y ejecutar acciones en un orden correcto recordando sus consecuencias sensoriales [113].

En la zona parietal se construye el modelo interno del movimiento, es decir, la preparación del movimiento. Lo que permite una predicción del resultado esperado de dicho movimiento y, por lo tanto, la intención de movimiento resulta más compleja que la simple disposición de moverse [103], [112]. Pues, como se mencionó en la sección 2.2.1, las zonas parietales permiten la coordinación de movimiento. Por medio de la corteza somatosensorial, la recepción y procesamiento de la

información corporal (p.ej., tacto, dolor, presión y temperatura), así como el mapa del cuerpo para localizar dichas sensaciones. Además, en el lóbulo parietal inferior se encuentra la percepción espacial. Mientras que en el lóbulo parietal superior procesa la orientación e información sensorial y visual de las manos. Finalmente, el precuneo se involucra en tareas la generación de imágenes mentales [113], la reactivación de información sensorial de recuerdos y la adopción de perspectivas en primera persona [43].

Los ganglios basales y el cerebelo: son regiones subcorticales implicadas en la activación de la intención de movimiento (ver Figuras 12 y 13), donde ambos contribuyen en el aprendizaje y preparación motriz, y conectadas con las áreas corticales relacionadas con la motricidad [103]. Específicamente, los ganglios basales (BG) se componen de una serie de núcleos subcorticales implicados en el control motriz y funciones ejecutivas (p.ej. aprendizaje motor, control de comportamiento y la emoción) [56]. Incluso, los BG se relaciona con territorios límbicos para mantener la estabilidad de su red. Esta relación juega un importante rol en la selección y el proceso de la actividad neuronal asociada al movimiento [56]. Además de que poseen conexiones con la corteza prefrontal importantes en el mantenimiento de representaciones motoras dinámicas en la memoria de trabajo [109].

Mientras tanto, el cerebelo normalmente es relacionado con la ejecución de movimiento real, en conjunto con áreas corticales motoras y la corteza parietal [114], debido al hecho de que la intención y ejecución de movimiento comparten vías comunes [75]. En el caso de la ejecución del movimiento, el cerebelo funciona como mediador en el sistema sensoriomotor implicándose en la retroalimentación somatosensorial del movimiento organizando una perfecta transferencia de la imagen interna del movimiento a las condiciones físicas reales del mundo exterior[115], es decir, el cerebelo contribuye a la representación interna del movimiento para control y coordinación [115]–[117]. El cerebelo es una estructura relacionada con el control balance, la coordinación, movimiento y habilidades

motrices, especialmente las relacionadas con aquellas que requieren de práctica y afinación; al igual que en el procesamiento de algunos tipos de memoria [68], [70].

En la intención de movimiento, el cerebelo contribuye con el control del M1 provocando la inhibición de comandos motrices [102], [103]. Hecho que fue demostrado por Cegiz y Boran en [75], donde se expone el efecto inhibitorio del cerebelo que evita que los impulsos evocados de la intención de movimiento lleguen a nivel medular y muscular. Tanto el cerebelo como los ganglios basales se involucran, como estructuras subcorticales, con la red de observación y ejecución para formar una red integrada, lo que supondría la existencia de mecanismos en estas estructuras subcorticales relacionadas con el aprendizaje de habilidades motrices, a través de la observación y la imitación [118].

Finalmente, y como se mencionó anteriormente, la intención de movimiento y la ejecución de movimiento comparten vías comunes de procesamiento en la corteza cerebral y zonas subcorticales [75]. Es por ello que el autor Jean Decety [109] menciona que la intención de movimiento debe considerarse como un proceso neuronal que involucra estructuras cerebrales específicas de importancia en el control cognitivo y planeación del movimiento. Pues, precisamente, estas estructuras participan en la ejecución real de movimiento, por medio de la ejecución apropiada de regiones sensoriomotoras.

2.4 Electroencefalograma

El cerebro humano cuenta con un aproximado de 10^{11} neuronas interconectadas por conexiones sinápticas [25] formando un sistema de comunicación de manera que las neuronas codifican y transfieren información [119]. I.e., las neuronas actúan como transportadoras de información entre el cuerpo y el cerebro [120]. Gracias a este complejo sistema, el cerebro responde ante los diversos estímulos externos generando potenciales eléctricos los cuales, son producto de la actividad neuronal. Estas señales pueden ser registradas por medio de un electroencefalograma (EEG) el cual, es la gráfica del registro de la actividad bioeléctrica cerebral por medio de electrodos situados en el cuero cabelludo o corteza cerebral [25], [121], [122].

Como definición, la electroencefalografía *“es una medición no invasiva de los campos eléctricos del cerebro”* [123], realizada por medio de electrodos colocados en el cuero cabelludo [124]. La actividad eléctrica registrada es reportada como señales electroencefalográficas y son creadas por las neuronas interconectadas en el cerebro donde funcionan como transportistas de información [120], [124]. De acuerdo con Keenan et al. [125], el registro de señales EEG permite el análisis de datos en los dominios de frecuencia y amplitud, es decir, tiempo y voltaje. Las señales EEG resultan ser complejas debido a que se componen de una mezcla de información: artefactos fisiológicos (movimientos oculares, musculares, latidos del corazón) o artefactos técnicos (línea de alimentación, desconexión del electrodo) [126].

La electroencefalografía tiene diferentes aplicaciones en dominios como la medicina, la educación, el entretenimiento [124], la neurociencia y la ingeniería biomédica *“debido a su alta resolución temporal, su carácter no invasivo y su costo relativamente bajo”* [127]. En el área de la salud, los estudios de EEG son utilizados como una herramienta importante para el diagnóstico, tratamiento y monitoreo de enfermedades y anomalías relacionadas con el cerebro y la mente [16], [17] como el síndrome epiléptico, demencia, el monitoreo de patrones de sueño

(desordenes del sueño), la profundidad de la anestesia, el trastorno de déficit de atención e hiperactividad, problemas de aprendizaje y trastornos de conducta. También, se cuentan con aplicaciones cognitivas y monitoreo como el nivel de fatiga, estado de ánimo, emociones y el control de estrés [124], [128], [129].

La señal registrada por el EEG presenta formas de onda complejas de hasta $200\mu\text{V}$, diferenciadas por su frecuencia, el número de repeticiones por segundo (Hz); y su amplitud, la diferencia entre el voltaje máximo y mínimo de cada onda [130]. Las ondas registradas son clasificadas según su contenido espectral en ondas alfa, beta, theta y delta [122].

Tabla 1. Frecuencias de ondas cerebrales [122], [131]

Tipo de onda	Banda de frecuencias	Amplitud
<i>Alfa</i>	8 a 12 Hz	$>20\ \mu\text{V}$
<i>Beta</i>	$>14\ \text{Hz}$	5 a $30\ \mu\text{V}$
<i>Theta</i>	4 a 7 Hz	$20\ \mu\text{V}$ aprox.
<i>Delta</i>	$<3.5\ \text{Hz}$	variable

Las ondas alfa representan un estado de poca actividad cerebral y relajación, pero despierto. Como se muestra en la Tabla 1, éstas tipo de ondas se encuentran en el rango de frecuencias entre 8 y 12 Hz, manifestando en el lóbulo occipital y frontal [121], [122].

Las ondas beta poseen una frecuencia mayor a 14Hz con voltaje entre 5 y $30\ \mu\text{V}$ [122], [132] (ver Tabla 1). Denotan una actividad mental intensa y se observan en un estado despierto, alerta o en resolución de problemas. Este tipo de ondas se presentan con mayor incidencia en el lóbulo frontal y parietal [131].

Las ondas theta se encuentran en frecuencias entre 4 y 7Hz [122] con una amplitud aproximada de $20\ \mu\text{V}$ [131], como se puede observar en la Tabla 1. Este tipo de ondas se registran durante un estado de calma profunda durante estados hipnóticos, meditación [131], [132]. Las ondas theta se relacionan además, con estados de inspiración y en la realización de tareas que se han automatizado [132].

Finalmente, las ondas delta poseen una amplitud variable y frecuencia menor a 3.5Hz [122] pero sin llegar a 0, pues eso significaría muerte cerebral [132]. [132]. Se relacionan a estados de sueño profundo sin presentar sueños.

El estudio de las señales EEG también ha sido relacionado con tareas de clasificación [127]. Entre las investigaciones más destacadas se encuentra el reconocimiento de emociones en neuromarketing para conocer mejor a los clientes [127], [133]; tareas de esfuerzo mental, la medición de la actividad mental mientras se resuelven tareas complejas [127], [134]; la detección de convulsiones, especialmente en pacientes epilépticos; la detección temprana de Alzheimer [127], [135]; la detección de etapas del sueño, para encontrar trastornos del sueño [17], [127]; la detección y evaluación del dolor (tipo, intensidad y origen) [136]; y tareas de intención de movimiento, para la detección de movimiento en músculos para el apoyo en el aprendizaje de movimientos complejos [95], [127]. Para conocer más sobre intención de movimiento, el lector puede consultar el tema en la sección 2.3.

2.5 Interfaz cerebro-computadora

Las interfaces cerebro-computadora (BCI, Brain-Computer interface) son sistemas de hardware y software [137] que permiten un enlace de comunicación directo entre el cerebro y un dispositivo externo, por medio de la medición de la actividad cerebral [138], [139].

Los BCI decodifican e interpretan el comportamiento fisiológico del cerebro (intención) a través de los potenciales eléctricos relacionados con eventos (ERP), para luego ser “traducidos” en comandos computacionales a los que responden dispositivos electrónicos [21], [139], [140]. Todo ello, sin que exista una intervención de algún músculo o una ruta neuromuscular para completar la comunicación, comando o acción [141]. Lo que se deriva en un nuevo canal de comunicación entre un sujeto y su entorno [142].

La posibilidad de comunicarse directamente con el cerebro ha crecido en interés desde la introducción del electroencefalograma (EEG) en 1929 por Hans Berger [143], provocando la creación de las BCI por J.J. Vidal en 1973 [138] y el desarrollado una gran variedad de aplicaciones médicas y científicas que permiten, no solo la investigación del funcionamiento del cerebro, sino que también posibilitan el diagnóstico, tratamiento y seguimiento de enfermedades neurofisiológicas y neuropsicológicas. Por ejemplo, la medición del nivel de consciencia en pacientes en coma o estado vegetativo, el entrenamiento de la atención en niños con TDAH y la interacción social en niños con autismo, así como la regulación cognitiva y afectiva en pacientes con esquizofrenia o epilepsia [139]. Incluso, se trabaja en el control de dispositivos a partir de la actividad cerebral de una persona [143]. Por ejemplo, videojuegos, prótesis, cursores, sillas de ruedas, domótica, exoesqueletos, etc. [144].

2.5.1 Elementos en una interfaz cerebro-computadora

La estructura básica de una interfaz cerebro-computadora comprende la adquisición, amplificación y digitalización de la actividad bioeléctrica cerebral; un grupo de métodos para el preprocesamiento, la extracción de características, y clasificación de las señales; y, finalmente, el control de un dispositivo [145], [146].

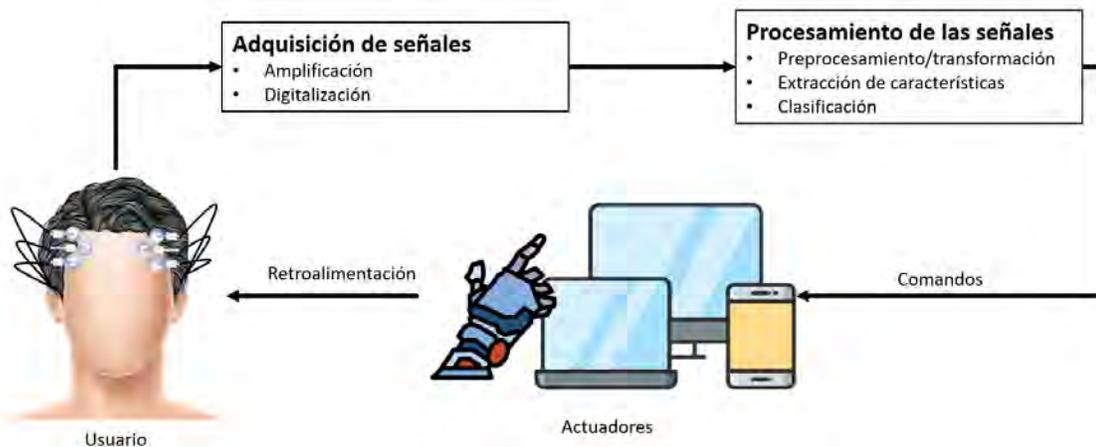


Figura 15. Estructura de un sistema de interfaz cerebro-computadora. Basado en los diagramas publicados en [145]–[147].

Como se puede apreciar, la Figura 15 muestra un modelo de interfaz cerebro-computadora para la interpretación de la actividad bioeléctrica del cerebro (ABC) y su conversión de comandos ejecutados por dispositivos externos (actuadores). Por parte, Piña Ramírez agrega en su tesis [145], el concepto de paradigma refiriéndose las fuentes electrofisiológicas, es decir, los mecanismos neurológicos utilizados por el usuario para generar cambios en su ABC [147]. Los paradigmas pueden dividirse en dos tipos, los endógenos y los exógenos. Los primeros comprenden la realización interna de una tarea mental, p. ej., la intención de movimiento (sección 2.3) o imaginar un objeto, animal o palabra. En este caso, cada tarea mental es traducida en comando a un dispositivo externo. Por otro lado, los paradigmas exógenos utilizan estímulos externos visuales, auditivos o somatosensoriales para provocar cambios específicos en la ABC.

Una vez definido el paradigma, el siguiente paso consisten en la adquisición (ver Figura 15) de la actividad electroencefalográfica u otras medidas electrofisiológicas de la función cerebral [145], [148]. La adquisición se realiza por medio de electrodos colocados en la cabeza los cuales, registran la señal del cuero cabelludo, de la superficie del cerebro o de la actividad neuronal del cerebro. Finalmente, la actividad cerebral es convertida a señales eléctricas [148]. Dentro de este proceso, las señales son amplificadas y digitalizadas para ser enviadas a dispositivos de almacenamiento y despliegue [145].

La adquisición puede realizarse de forma no-invasiva (electroencefalografía <EEG>, magnetoencefalografía <MEG> o neuroimagen <IRMf>) [144] o de forma invasiva (intra cortical) [149]. Esta última requiere de la implantación de electrodos mediante intervención quirúrgica para penetrar el sistema tegumentario, en el espacio subdural o sobre la corteza cerebral. Sin embargo, resulta la manera más efectiva de adquisición de la ABC, pues cuenta con mayor resolución espacial y especificidad temporal [144]. La electroencefalografía, específicamente, resulta ser la técnica más común para la detección de la actividad neuronal (ver sección 2.4). Pues se trata de un método relativamente económico y versátil [139]. Sin embargo, existe el inconveniente de que las interfaces cerebro-computadora con electroencefalograma (BCI-EEG) no son sistemas estándar, es decir, cada módulo debe ajustarse a cada usuario individualmente debido a la gran variabilidad de las señales EEG. Lo que resulta en que un modelo de BCI no puede ser reproducible entre diferentes usuarios [139].

El siguiente módulo en un sistema BCI es el procesamiento de la señal. Como se observa en la Figura 15, éste contempla el preprocesamiento, la extracción de características y la clasificación de la señal para, finalmente, entregar un comando de salida que será ejecutado por el actuador.

La etapa de preprocesamiento permite la adecuación y estandarización de la señal capturada. Esto debido a que la señal eléctrica del cerebro es compleja pues se componen de la suma de la actividad de diferentes poblaciones neuronales [15],

[150], [151] y puede verse contaminada por otras fuentes de actividad fisiológica o actividad bioeléctrica, movimientos corporales, ruido eléctrico ambiental [145]. Las técnicas más populares en el preprocesamiento de señales son el filtrado, normalización, eliminación de la tendencia y promedios coherentes [145].

El siguiente elemento es la extracción de características o la extracción de rasgos (ver Figura 15) [145], [149] en el cual, se extraen las características de la señal que codifican los mensajes o comandos del usuario [149]. En este paso, las señales EEG son representadas en formas alternativas, generalmente en un dominio diferente en el que se resalte la información relevante [145]. Dependiendo del objetivo del sistema BCI, éste puede utilizar características del dominio de tiempo, p. ej., amplitudes de potenciales evocados o tasas de disparos neuronales. También, un sistema BCI puede orientarse al dominio de la frecuencia, p. ej., amplitudes de ritmos mu (μ) o ritmos beta (β) [149].

El último elemento en el módulo de procesamiento de un sistema BCI (Figura 15) es la clasificación o traducción de la señal EEG. Es decir, es en este punto donde se asigna una etiqueta de clase de acuerdo con una regla de decisión [145]. De esta manera, se convierte la señal EEG procesada en un comando u orden que obedece a la intención del usuario [149]. La clasificación puede realizarse por medio de métodos de clasificación lineal, como el análisis estadístico clásico; o por métodos no lineales, como las redes neuronales artificiales [148], [149]. Sin embargo, sea cual sea la naturaleza del algoritmo de clasificación, éste transformará las señales procesadas (variables independientes) en comandos de control (variables dependientes) para los actuadores.

La etapa de procesamiento es, actualmente, una prioridad en el desarrollo de sistemas BCI. Es decir, la búsqueda de algoritmos de procesamiento que permitan la extracción y clasificación de características distintivas de las señales EEG [146].

El último elemento de un sistema BCI son los actuadores o dispositivos (ver Figura 15) que ejecutan el comando resultante del módulo de procesamiento [145], [149]. Adicionalmente, estos dispositivos proveen una retroalimentación al usuario

que puede ser usada como mantener o mejorar la precisión y velocidad de la comunicación cerebro-dispositivo [149].

2.5.2 Clasificación de sistemas BCI

Hasta este punto, se ha definido que una BCI es un sistema que mide la actividad bioeléctrica del cerebro y “la convierte en salidas artificiales que reemplazan, mejoran y suplementan salidas naturales” [139] de la actividad cerebral. De esta manera, las interacciones del cerebro con el exterior se realizan a través de una BCI.

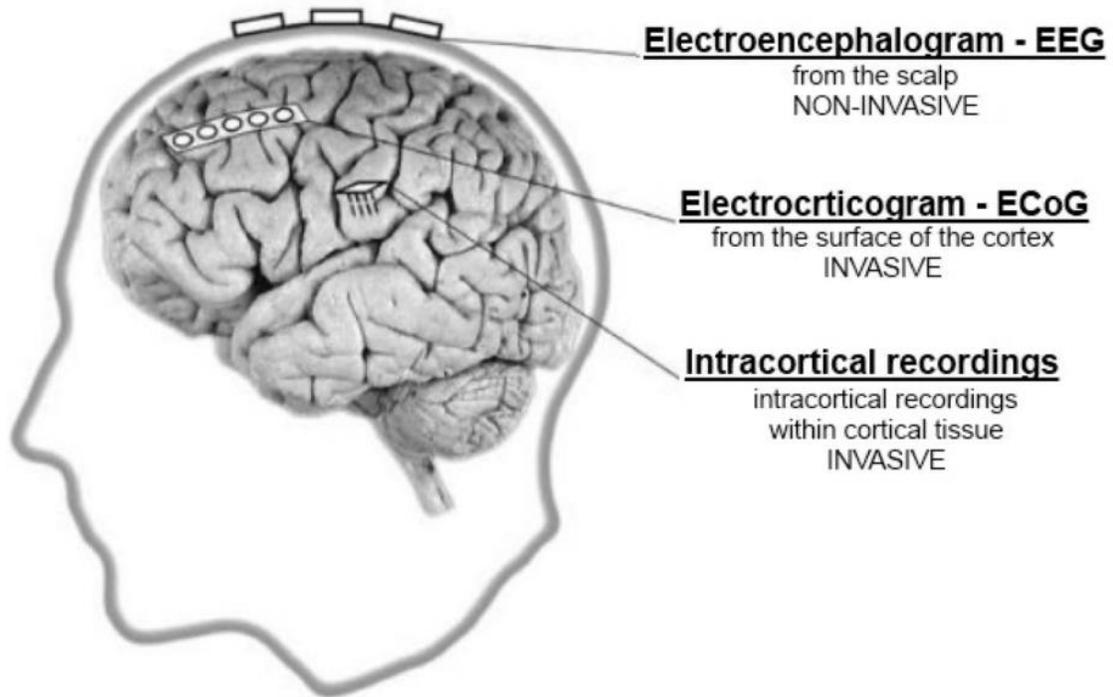


Figura 16. Métodos para el registro de la actividad cerebral. Extraído de [152].

En la literatura es posible encontrar diferentes maneras de clasificar sistemas BCI. La más sencilla de ellas, consiste en clasificarlos de acuerdo con el método de adquisición de la actividad cerebral[144]. En este caso, los tipos de BCI son:

- **Invasivos:** el registro de la actividad cerebral se realiza de forma intracraneal o intracortical [147], como se muestra en la Figura 16. En otras palabras, requiere de intervención quirúrgica para implantar los electrodos de lectura. En este caso, la señal es de alta calidad con mayor resolución espacial y especificidad temporal con el riesgo que implica un proceso quirúrgico [137], [144].
- **No-invasivos:** en este caso (Figura 16), la lectura se realiza por medio de electrodos colocados sobre el cuero cabelludo, sin la necesidad de cirugía[141]. Sin embargo, la señal posee menor calidad, aunque resulta la manera más conveniente para registrar la actividad cerebral [137]. Entre las lecturas no invasivas se tienen la electroencefalografía (EEG), magnetoencefalografía (MEG), la tomografía por emisión de positrones (PET), la resonancia magnética funcional (fMRI) y la espectroscopía funcional del infrarrojo cercano (fNIRS) [141].
- **Semi invasivos:** los electrodos son implantados entre el cráneo y el cerebro y las lecturas son realizadas por medio de electrocorticografía (ECoG). Al ser una medición más cercana al cerebro, posee menor ruido, mejor resolución espacial y una mejor precisión y sensibilidad que los métodos no invasivos [137].

De acuerdo con Valerdi et al. [139] exponen la clasificación de cuatro tipos de interfaces, activas, reactivas, pasivas e híbridas, tal como se muestra en la Figura 17. Los sistemas BCI-activos son controlados a voluntad por el usuario, es decir, requieren de su control consciente por lo que proporcionan la libertad de manipular el actuador (Figura 15). Este tipo de BCI se especializa en la detección de tareas de control endógenas. Las cuales, se refieren a esfuerzos mentales que modulan la actividad neuronal significativamente [139], es decir, estímulos que parten del usuario [146].

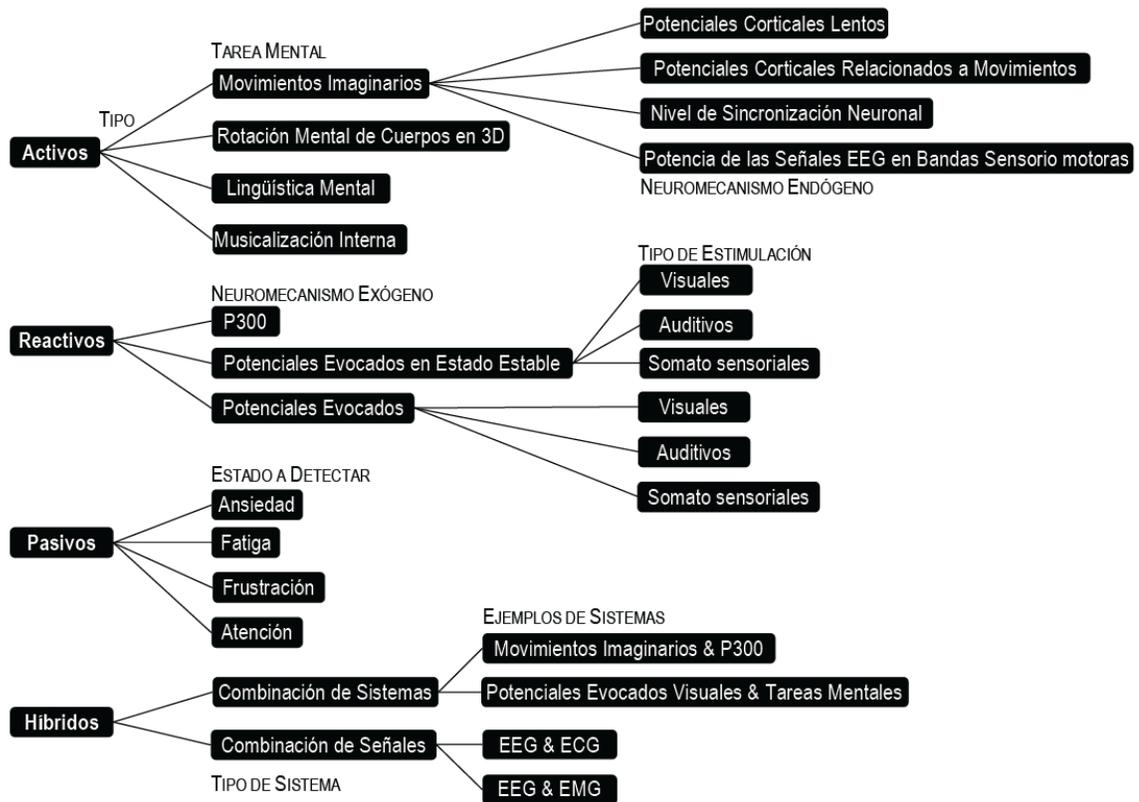


Figura 17. Clasificación de sistemas de interfaz cerebro-computadora. Obtenida de [139].

Como se recordará, el principal objetivo del uso de sistemas BCI es la detección de intención de movimiento (sección 2.3) que, precisamente, es detectado por las BCI-activas por medio de potenciales corticales lentos (SCP) [153]. Los SCP están asociados a actividades motrices e intención de movimiento (imaginación motora) [142]. De acuerdo con Bashashati et al. [148] y Tibrewal et al. [154], la intención de movimiento modifica la actividad sensoriomotora de manera similar al movimiento real. La actividad sensoriomotora es un neuromecanismo que comprende cambios en los ritmos μ (8-12Hz) y β (13-30Hz), ambos originados en la corteza sensoriomotora cuando el usuario produce una intención de movimiento [137]. Este tipo de variaciones son mayormente predominantes en zonas frontales y prefrontales. La intención de movimiento una de las tareas de control en la construcción de sistemas BCI, debido a la capacidad de generar patrones reconocibles en zonas sensoriomotoras primarias [139].

Los sistemas BCI-reactivos son aquellos en los que se mide la reacción del usuario después de un estímulo sensorial externo, p. ej., visual, auditivo, táctil u olfativo. Como se puede observar, en esta ocasión la tarea a medir es exógena pues, canalizan la atención del usuario por medio de estímulos externos [139]. La ventaja de los BCI-reactivos es que no requieren de un entrenamiento previo por parte del usuario, sin embargo, requiere de estímulos repetitivos que pueden provocar cansancio en inconsistencia [137], [139].

Por su parte, los BCI-pasivos son utilizados para el análisis de la actividad neuronal para detectar estados cognitivos (p. ej., cansancio, sueño, ansiedad, o nivel de atención, por mencionar algunos) [139].

Finalmente, los BCI-híbridos que, como su nombre lo indica, toma los mecanismos neurofisiológicos de las BCI activas y reactivas para su funcionamiento [139]. El objetivo de usar más de un tipo de señales en un sistema BCI es la fiabilidad y evitar las desventajas de cada tipo de señal [137]. Incluso, el término híbrido también hace referencia a la posibilidad de combinar la actividad neuronal con otro tipo de señales fisiológicas, entre las que se encuentran el ritmo cardiaco, la respiración o la conductividad de la piel [139].

2.6 Reconocimiento de patrones

El reconocimiento de patrones es un área multidisciplinaria encargada de extraer información de objetos que permita establecer propiedades de o entre conjuntos de estos objetos, es decir, clasificar y recuperar características únicas que identifiquen objetos pertenecientes a una misma clase [155]–[157].

De acuerdo con Anzai [158], “reconocimiento” se refiere a saber de nuevo lo que ya se sabía. En este sentido, dentro de las ciencias computacionales, “reconocimiento” significa reconocer patrones de objetos que son los mismos que la máquina ya había observado. Donde el patrón de un objeto es toda la información que se posee del objeto o fenómeno a estudiar.

En sí mismo, el reconocimiento de patrones representa un objetivo esencial tanto para el aprendizaje máquina como para la inteligencia artificial, especialmente en la solución de problemas de alto nivel; donde su éxito recae en gran medida del reconocimiento preciso y automático de patrones [159].

El reconocimiento de patrones se encarga principalmente del desarrollo de teoría y métodos para la solución problemas de [160]:

- **Agrupamiento (clustering):** Formación natural de grupos de objetos, también conocida como clasificación no supervisada, donde dada una muestra de objetos, se separan en grupos de objetos que son similares entre sí y, a la vez, diferentes a los pertenecientes a otros grupos [155], [160], [161].
- **Clasificación:** o clasificación supervisada la cual, busca predecir la clase de objetos nuevos [160]. Es decir, dado un universo de estudio con objetos separados por clases y una muestra de estos ya clasificados, la clasificación supervisada busca mecanismos que permitan la clasificación de objetos nuevos [155].

- **Reducción de la dimensionalidad:** o selección de características tiene como objetivo principal extraer características significativas de una medición [160]. Comprende una serie de técnicas utilizadas como preprocesamiento para agrupamiento y clasificación. Sin embargo, la selección de características es un problema importante por sí misma [155]. El objetivo principal, es eliminar características redundantes e irrelevantes y erróneos, mejorando procesos de aprendizaje y reduciendo la complejidad del modelo de entrada [162] con una representación estable de objetos facilitando la comprensión de datos [163], [164].

Un modelo o sistema de reconocimiento consta de un vector p -dimensional $x = (x_1, \dots, x_p)^T$ al que se le conoce como patrón. Donde cada x_i denota la medición de una característica del objeto. Donde cada x_i puede ser representado como un punto en un espacio de características de dimensión p [165], [166]. Además, existe un conjunto de clases $C = \{w_1, \dots, w_C\}$ y una variable categórica z asociada a cada patrón que denota la clase a la que pertenece (si $z = i \rightarrow$ el patrón $x \in w_i, i \in \{1, \dots, C\}$) [165]. Este tipo de modelos puede ser abordado desde los siguientes enfoques [155], [166]:

- **Enfoque estadístico:** Dado un conjunto de objetos de cada clase como entrenamiento, el objetivo es establecer límites de decisión en el espacio de características, los cuales, dentro del enfoque estadístico, están determinados por las distribuciones de probabilidad de cada clase que son especificadas o aprendidas por el modelo de clasificación [166]. Es decir, cada patrón dado se asigna a una de las C clases basado en su vector de características $x = (x_1, \dots, x_p)^T$, donde se asume que cada característica tiene una función de probabilidad, de densidad o masa (características continuas o discretas) condicionada a la clase de patrón. Así, un vector x que pertenece a la clase w_i se puede observar como una función de probabilidad condicional $p(x|w_i)$ [166].

- **Enfoque sintáctico:** A diferencia del enfoque estadístico, el enfoque sintáctico estudia objetos que no pueden ser descritos como vectores de características [155]. Se basa en patrones descritos estructuras de datos simbólicas (p. ej. cadenas, árboles, arreglos o grafos) [167]. En este caso, la comparación de objetos se realiza mediante una coincidencia simbólica que mide la similitud entre un objeto desconocido y los modelos predefinidos [167], [168].
- **Enfoque neuronal:** Se especializa en la solución de problemas de reconocimiento de patrones por medio de modelos de redes neuronales artificiales [155]. Las redes neuronales artificiales son descritas como sistemas de procesamiento paralelo compuesto por procesadores simples (neuronas artificiales) interconectadas. Lo que las convierte en poderosas herramientas universales con la capacidad de aprender relaciones complejas no lineales, así como la capacidad de adaptabilidad, generalización, tolerancia a fallos y representación distribuida [166], [169]. Para conocer más acerca de redes neuronales, consultar la sección 2.12.2.
- **Enfoque lógico-combinatorio:** Permite el modelado de problemas bajo una estricta relación con el contexto real del problema, sin suposiciones no fundamentadas. Todo esto fundamentado en la lógica matemática, la teoría de testores, la teoría clásica de conjuntos, la teoría de subconjuntos difusos, la teoría combinatoria y la matemática discreta [170]. Este enfoque permite el tratamiento simultaneo de características cuantitativas, cualitativas y con la ausencia de información [155] con una metodología de modelación matemática [170]. Bajo este enfoque, se parte de una muestra inicial (MI), subconjunto de un universo U , y una función de semejanza β . Se busca identificar a cada objeto a una agrupación a la cual, el objeto responderá de manera “natural” de acuerdo con el comportamiento general o individual de sus semejanzas con otros objetos o el cumplimiento de una propiedad en particular [171].

Ridder et al. [160] mencionan que las aplicaciones de reconocimiento de patrones siguen una serie de pasos como se muestra en la Figura 18. El primer paso (A) consiste en la recolección de datos por medio de un instrumento de medición donde se asume que el conjunto de datos es representativo del problema a analizar.

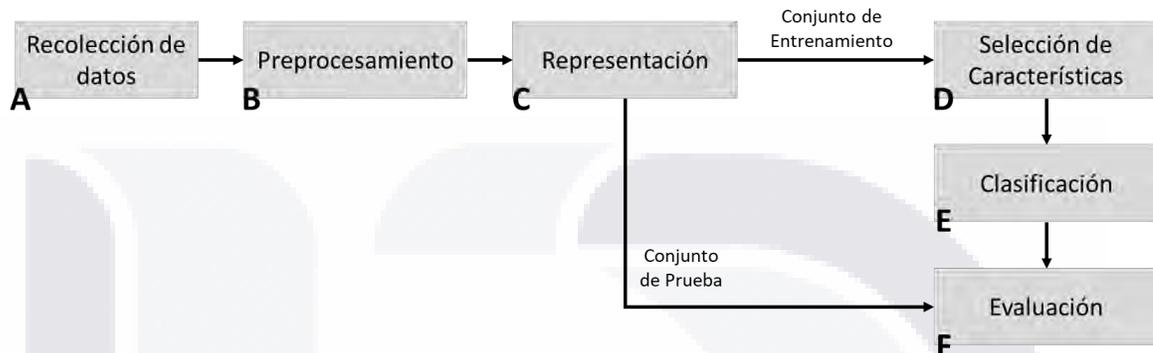


Figura 18. Proceso de reconocimiento de patrones para clasificación. Basado en [160].

El preprocesamiento (B) a elegir depende del conocimiento previo disponible del problema y se describe como una inspección de calidad. Dicha inspección consiste en detectar y eliminar problemas como errores de medición o valores omitidos. La representación de datos (C) se da normalmente como características, de manera que se cuenta con mediciones correctamente representadas.

La selección de características (D) reduce la dimensionalidad del problema, es decir, reduce el número de características que describen los objetos estudiados. Así, se eliminan características redundantes o irrelevantes obteniendo un conjunto más apropiado para los siguientes pasos [160], [165] (ver sección 2.7). Webb [165] menciona el término dimensionalidad intrínseca para referirse a la mínima cantidad de variables necesaria para capturar la estructura dentro de los datos.

El conjunto de datos definido por un subconjunto de características descriptivas es dividido en dos subconjuntos. El primero de ellos, el conjunto de entrenamiento permite al clasificador (E) establecer los parámetros necesarios para predecir la clase de un objeto, dado el conjunto de mediciones observadas [160]. Finalmente,

el conjunto restante, el conjunto de prueba, permite evaluar el desempeño del clasificador con datos desconocidos para él.

Como se puede observar, el reconocimiento de patrones requiere de mediciones, validaciones, procesamiento y la interpretación de la información en el entorno. Por lo tanto, el reconocimiento de patrones se puede considerar como la formalización de procesos para la interpretación del mundo real [155].

2.7 Selección de características

En la actualidad, se genera gran cantidad de información en tiempo real como consecuencia del aumento de dispositivos interconectados (ej. Datos de internet de las cosas, ciberseguridad, datos móviles, redes sociales y sistemas de salud [9], [172], [173]. Esto resulta en modelos matemáticos, estadísticos e informáticos con estructuras multidimensionales para visualización, inferencia y aprendizaje más complejos y computacionalmente demandantes (tiempo de procesamiento y espacio de almacenamiento) [172], [173]. Pues, trabajar con datos de alta dimensionalidad implica la existencia de características irrelevantes. Es por ello, que se han creado herramientas con la capacidad de extraer información útil de conjuntos brutos de manera eficiente e inteligente [9], [174]. Este tipo de herramientas corren a cargo del reconocimiento de patrones, específicamente de la selección de características [172], [174].

El término de selección de características se usa para describir herramientas y técnicas, dentro de la minería de datos y el aprendizaje automático, que permiten *“la reducción eficiente del número de variables o características con las cuales se deben describir objetos y para encontrar las variables que inciden de forma determinante en un problema”* [175], [176]. Las técnicas de selección de características son diseñadas, generalmente, para problemas de clasificación y regresión [177]. Se trata de herramientas de descubrimiento de conocimiento que

permiten un mejor entendimiento de los datos estudiados, una mejor generalización y, por supuesto, la identificación de ruido producido por errores de medición, errores de captura, casos atípicos o redundantes que no contribuyen a la calidad de la solución [155], [178]. De esta manera, la selección de características permite un mejor desempeño de los modelos predictores incrementando, también, su eficiencia en términos de costo, tiempo y espacio de almacenamiento [178], además de proveer un mejor entendimiento del proceso base que generó los datos [179], [180].

Para el desarrollo de este trabajo de tesis, se trabajó el proceso de selección de características aplicando la teoría de testores, correspondientes al enfoque lógico combinatorio desarrollado por la ex Unión Soviética destacando por la posibilidad de trabajar con cualquier tipo de variable sin importar la alta complejidad de los algoritmos [155], [181].

2.7.1 Teoría de testores

La teoría de testores fue formulada como dirección científica de Cibernética Matemática en los años 60 en la Unión de Repúblicas Socialistas Soviéticas (URSS), vinculándose, en principio, con el uso de lógica matemática para localizar fallas en circuitos electrónicos que realizan funciones booleanas [182].

La teoría de testores es parte de la variedad de herramientas y metodologías aplicadas para abordar la selección de características, especialmente, cuando se trabaja con datos cuantitativos y cualitativos e, incluso, incompletos [183]. A su vez, la teoría de testores forma parte del enfoque lógico combinatorio [157], [182], [184].

El enfoque utilizado para este trabajo de tesis fue creado en 1965 de Dimitriev, Zhuravlev y Krendeleiev para problemas clásicos de reconocimiento de patrones (clasificación y selección de características, ver sección 2.5). En este enfoque *“las clases son conjuntos disjuntos, el criterio de comparación entre rasgos es booleano y el criterio de semejanza entre objetos asume que dos objetos son diferentes si al menos uno de sus rasgos también lo es”* [185].

Para la aplicación de la teoría de testores, dentro del enfoque de Zhuravlev, tiene como requerimiento un conjunto de datos (matriz de aprendizaje, MA) con k objetos descritos por n características $R = \{x_1, \dots, x_n\}$, (conjunto completo de características, ver Figura 19) agrupados en r clases [186]. Donde cada atributo que describe los objetos posee un criterio de comparación booleana. Es importante recordar que las clases representan conjuntos disjuntos, es decir, el criterio de similitud entre dos objetos asume que son diferentes si al menos una de sus características también son diferentes [185], [186].

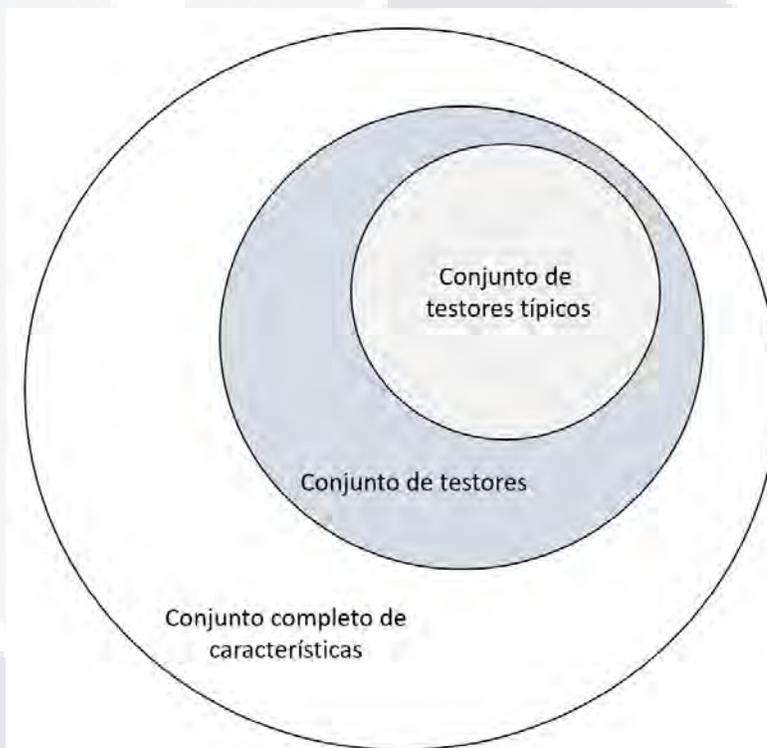


Figura 19. Conjunto de características, testores y testores típicos. Obtenida de [157].

Un testor, definido por la teoría de testores, es un subconjunto de características (ver Figura 19) con la capacidad de distinguir objetos de diferentes clases [187], donde ningún objeto de la clase T_0 se puede confundir con algún objeto de la clase T_1 observarse a través de los valores de sus características [188].

Shulcloper et al. [189] extienden la definición de testor a más de dos clases por lo que, dado un subconjunto de columnas $\tau = \{i_1, \dots, i_s\}$ de la tabla T y sus rasgos

$(\alpha_{i_1}, \dots, \alpha_{i_s})$, se considera testor para $(T_0, \dots, T_r) = T$, si después de eliminar de T todas las columnas de τ no existe alguna fila en T_0 igual a una en cualquiera del resto de las τ clases T .

Además, dentro del conjunto de testores se encuentra el conjunto de testores típicos o testores irreducibles (ver Figura 19), los cuales son testores que si perdieran cualquiera de sus características perderían a su vez el estado de testor [175], [189]. Por tanto, un testor típico es un testor en forma más compacta [183], es decir, es el subconjunto de características mínimo necesario para diferenciar objetos de diferentes clases [187] como el conjunto de características completo [186]. Además de las tareas de selección de características y agrupación, el conjunto de testores típicos permite determinar la relevancia de cada característica en problemas de clasificación supervisada por medio del cálculo del peso informacional [183], el cual es descrito más adelante.

A continuación, en el apartado 2.7.2 se describe el modelo exhaustivo para la obtención del conjunto de testores y el conjunto de testores típicos.

2.7.2 Modelo exhaustivo para la obtención de testores y testores típicos

La obtención de testores típicos comienza por la obtención de la matriz de aprendizaje (MA) que contiene las descripciones del conjunto de objetos $\Omega = \{O_1, O_2, \dots, O_m\}$ en términos de sus n rasgos $\mathcal{R} = \{X_1, X_2, \dots, X_n\}$ divididos en r clases y un conjunto de criterios de comparación, donde cada criterio C_k se asocia a un rasgo X_k del conjunto \mathcal{R} [175]. El criterio de comparación con igualdad estricta y el criterio de comparación con error admisible se muestran a continuación:

$$1) \quad C_k(X_k(O_i), X_k(O_j)) = \begin{cases} 0 & \text{si } X_k(O_i) = X_k(O_j) \\ 1 & \text{e. o. c} \end{cases} \quad \text{“Criterio de comparación de igualdad estricta”}$$

$$2) \quad C_k(X_k(O_i), X_k(O_j)) = \begin{cases} 0 & \text{si } |X_k(O_i) - X_k(O_j)| \leq \varepsilon \\ 1 & \text{e. o. c} \end{cases} \quad \begin{array}{l} \text{“Criterio de comparación} \\ \text{con error admisible”} \end{array}$$

Dada una MA y un conjunto de criterios de comparación $\{C_1, C_2, \dots, C_n\}$, se obtiene una matriz de diferencias (MD). Una MD es una matriz de comparación binaria obtenida de la comparación de cada característica de dos objetos de la MA pertenecientes a clases diferentes [185], [186]. Esto es, la comparación de cada característica agrega un valor de cero si ambos objetos son iguales en esa característica, y toma un valor de uno si son diferentes [186]. La matriz de diferencias se compone de m' filas [189]: suponiendo que existen r clases (m_1, m_2, \dots, m_r) , donde cada m_i representa el número de objetos que pertenecen a la clase i , la MD tendrá:

$$m' = m_1(m_2 + \dots + m_r) + m_2(m_3 + \dots + m_r) + \dots + (m_{r-1})m_r \text{ renglones} \quad (1)$$

El siguiente paso consiste en calcular la matriz básica (MB) que, como su nombre lo indica, es una reducción de la MD que contiene sus filas básicas.[175]. En otras palabras, la MB sintetiza la información contenida en la MD al eliminar toda información redundante [186], esto es, renglones que son superconjuntos del resto. De manera formal, suponiendo que i_p e i_t filas de una MD, se dice que i_p es subfila de i_t (i_t es superfila de i_p) si y solo si:

- a) $\forall (a_{i_t j} = 1 \Rightarrow a_{i_p j} = 1)$ En todas las columnas donde i_p tiene 1, i_t también.
- b) $\exists_{j_0} (a_{i_t j_0} = 1 \wedge a_{i_p j_0} = 0)$ Existe al menos una columna en la que i_t tiene 1 e i_p no lo tiene.

i_t , como fila de MD, es básica si y solo si, en la MD no existe fila i_p alguna que sea subfila de i_t . Así, la MB se compone de las filas básicas de la MB excluyendo filas repetidas [157].

En este punto, la matriz de aprendizaje, la matriz de diferencias y la matriz básica aportan la misma información desde el punto de vista de la diferenciación de objetos con la diferencia de que a cada una es una representación cada vez más compacta conforme se van obteniendo [157].

Una vez se cuenta con la MB, se procede con la obtención del conjunto potencia (CP) utilizado por algoritmos de escala exterior [190]. El CP representa los potenciales testores, conformado por una matriz de 2^n filas de cadenas binarias de n elementos, siendo n es la cantidad de características que supone el problema analizado.

Cada fila del CP representa un subconjunto diferente de características $\tau \subseteq \mathcal{R}$ de una MA que puede ser testor si al eliminar de su MB todas las columnas, excepto aquellas que corresponden a los elementos de τ , no existen filas completas de ceros [157], [175], tal como se muestra en la Figura 20.

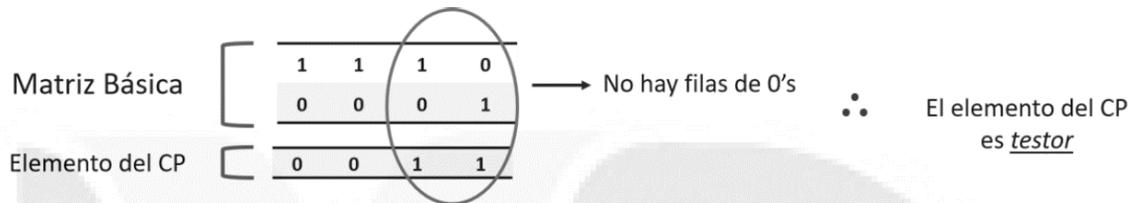


Figura 20. Obtención de testores a partir del conjunto potencia. Obtenida de [175].

Ahora, un subconjunto de características $\tau \subseteq \mathcal{R}$ es un testor típico en una matriz básica (MB) si τ es testor y no existe algún otro testor τ' donde $\tau' \subseteq \tau$ [186], [189], [191]. Por tanto, un testor típico es un testor irreducible, es decir, cada característica o atributo en un testor típico es esencial para calificar como testor. Es importante mencionar, que cada testor típico preserva la habilidad de discernir clases como el conjunto original de características [186].

La importancia del cálculo de testores típicos radica en la reducción del espacio de representación de características, es decir, el proceso de selección de características, como apoyo a sistemas de reconocimiento de patrones y clasificación [192]. Sin embargo, la teoría de testores puede aplicarse para

determinar la relevancia de cada característica por medio del cálculo del peso informacional, una puntuación determinada a cada característica. Dicha puntuación es obtenida a partir del cálculo de la frecuencia relativa de cada característica. Siendo τ el número de testores típicos obtenidos en un problema particular y $\tau(i)$ el número de testores típicos en los que apare la característica x_i , el peso informacional (P) está dado por [193]:

$$P(x_i) = \frac{\tau(i)}{\tau} \text{ Para } i = 1, \dots, n, \text{ para } x_i \in R \quad (2)$$

El peso informacional representa una medida de significancia para cada una de las características involucradas en el proceso de clasificación [194]. Esto es, entre más recurrente sea una característica en diferentes testores típicos, será más complicado poder descartarla y, por lo tanto, se trata de una característica que aporta mayor peso en la diferenciación de clases [193]. Finalmente, el cálculo del peso informacional funciona como una herramienta para la selección de características que muestra resultados tangibles del cálculo de testores típicos.

2.8 Heurísticas y metaheurísticas

En el mundo existen problemas cuya solución puede ser determinada de manera relativamente fácil bajo el diseño de un método exacto [195]. Sin embargo, también existen problemas muy complejos en campos como la economía, el comercio, la ingeniería, comunicaciones, la industria, la medicina, etc. cuya solución no se puede dar por medio de un modelo exacto y, aunque existiera, el tiempo y otros recursos son factores críticos en muchos de estos problemas [196], [197].

Para estos casos se han desarrollado algoritmos aproximados capaces de proporcionar soluciones de alta calidad en tiempos aceptables, sin embargo, esto

no significa que proporcionen necesariamente en una solución óptima. A este tipo de algoritmos se les conoce como heurísticas y metaheurísticas [196].

2.8.1 Heurísticas

En la actualidad existen innumerables problemas de gran interés para los cuales, no se conoce un algoritmo exacto de complejidad polinómica para la obtención de una solución óptima dentro de un espacio de búsqueda extenso y con un tiempo aceptable [198]. Para ello existen métodos de aproximación conocidos como heurísticas, que se definen como técnicas de indagación y búsqueda. En comparación con las soluciones heurísticas, las soluciones exactas requieren un tiempo de inversión tan grande que puede llegar a ser inaplicable [195].

De manera formal, Zanakis et al. [199] definen el término de heurística desde el punto de vista computo-matemático como *“un procedimiento simple, a menudo basado en el sentido común, que supone la obtención de una buena solución no necesariamente óptima a problemas difíciles de modo sencillo y rápido”*. Para Cunqueiro [195] una heurística es *“un procedimiento para resolver un problema complejo de optimización mediante una aproximación intuitiva”*.

La principal desventaja de las heurísticas es su incapacidad de salir de óptimos locales, que posiblemente sean de baja calidad, debido a que no cuentan con los mecanismos adecuados para continuar la búsqueda incluso después de encontrar un óptimo local [198]. Para ello, se han diseñado nuevos procedimientos de alto nivel que evitan esta desventaja conocidos como metaheurísticas [200] descritos en el apartado siguiente.

2.8.2 Metaheurísticas

El término metaheurística (meta-heurística o heurística moderna) es un término acuñado a Fred Glover en 1986 [201] para referirse a heurísticas de nivel superior. Glover definía dicho término como *“procedimientos de alto nivel que guían y modifican otras metaheurísticas para explorar el espacio de soluciones más allá del simple óptimo local”* [198].

La lógica general de una metaheurística parte de una solución inicial o un conjunto de ellas, que seguramente no es óptima, del cual se eligen aquellas que cumplan con un criterio definido para la producción de un nuevo conjunto de soluciones [202].

Las metaheurísticas son ciegas, es decir, no saben en qué momento encontraron una solución óptima por lo que requieren de la definición de criterios para indicar el momento de detener la búsqueda. Al igual que las heurísticas, no tiene la garantía de una solución óptima. Según su diseño pueden aceptar malas soluciones que les permiten explorar otras regiones del espacio de soluciones. Finalmente, las metaheurísticas son mecanismos relativamente sencillos de implementar con la inclusión de una representación del espacio de soluciones, un conjunto inicial de soluciones y un mecanismo de exploración [203].

2.9 Aprendizaje automático

El aprendizaje automático, o machine learning (ML) ha ganado importancia en la última década en muchos ámbitos científicos y en aplicaciones comerciales [204], [205]. Incluso, hoy en día, los sistemas inteligentes que ofrecen capacidades de inteligencia artificial se basan, precisamente, en aprendizaje automático [206]. Por ejemplo, Amazon lo utiliza para predecir los productos que un usuario podría comprar en un futuro; Netflix, lo aplica en sus algoritmos de recomendaciones; y Gmail, filtra mensajes de spam de la bandeja de entrada [207].

El aprendizaje automático describe la capacidad de los sistemas para aprender de los datos que conforman un problema específico para automatizar la construcción de modelos descriptivos y resolver tareas asociadas [206]. Es decir, enseñar a las máquinas a aprender de la experiencia [207], buscando automáticamente relaciones y patrones a partir de ejemplos y observaciones [206].

De manera formal, se puede definir al aprendizaje automático como una *“rama de la inteligencia artificial cuyo objetivo es el desarrollo de técnicas que permitan a las computadoras aprender, es decir, es la creación de algoritmos capaces de generalizar comportamientos y reconocer patrones a partir de la información suministrada en forma de ejemplos”* [208], [209]. También puede definirse como: *“el estudio de algoritmos de computación que mejoran su rendimiento automáticamente gracias a la experiencia. Se dice que un programa informático aprende sobre un conjunto de tareas, gracias a la experiencia y una medida de rendimiento, si su desempeño en dichas tareas mejora con la experiencia”* [210].

En el libro Machine learning in radiation oncology [211] se menciona que el aprendizaje automático, debe su funcionamiento a la incorporación de ideas extraídas de la neurociencia, probabilidad y estadística, ciencias computacionales, teoría de la información, psicología, teoría del control y filosofía. Lo que resulta en aplicaciones exitosas en visión por computadora, robótica, entretenimiento,

ecología, reconocimiento de patrones, finanzas, biología y medicina [212]. Por ejemplo: diagnósticos médicos, clasificación de secuencias de ADN, el análisis del mercado de valores, detección de fraudes, reconocimiento de habla y lenguaje, etc. [209].

Cabe recalcar que términos como inteligencia artificial, aprendizaje automático, minería de datos y aprendizaje profundo están tan estrechamente relacionados [212]. Pues, gracias a su crecimiento y popularidad, pueden llegar a ser términos confusos de entender y usarse indistintamente [213]. Sin embargo, como se muestra en la Figura 21, son conceptos diferenciables.

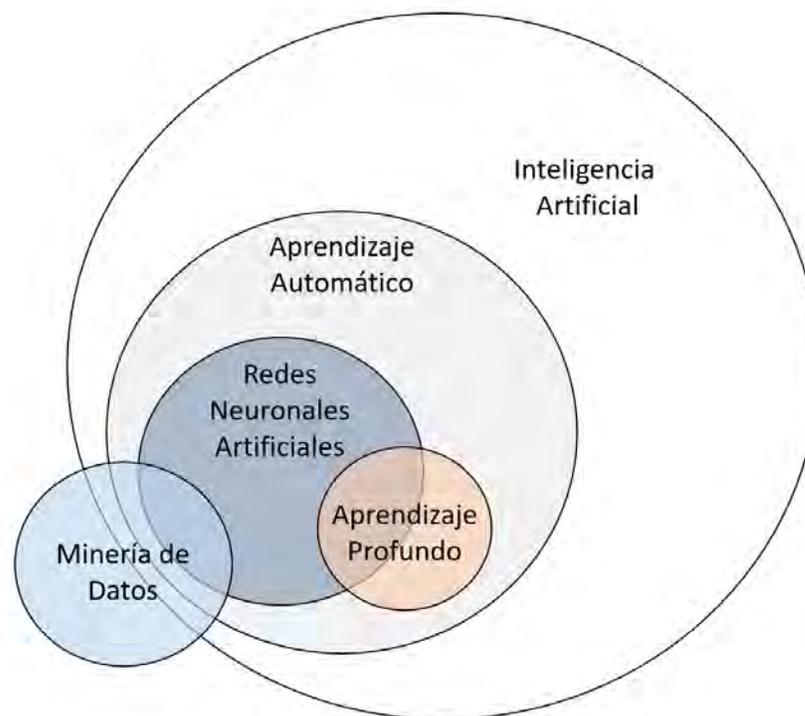


Figura 21. Relación entre inteligencia artificial, aprendizaje automático, redes neuronales artificiales, aprendizaje profundo y minería de datos. Traducción del original publicado en [214].

La inteligencia artificial (IA) comprende una serie de técnicas que permiten a las máquinas simular comportamientos humanos para la solución de problemas complejos con poca o nula intervención humana. Dichas tareas incluyen

representación del conocimiento, razonamiento, aprendizaje, planeación, percepción y comunicación. Tareas que, a su vez, se relacionan con un conjunto de herramientas como razonamiento basado en casos, sistemas basados en reglas, algoritmos genéticos, modelos difusos, por mencionar algunos [206]. En resumen, el término de inteligencia artificial se refiere a la ciencia y la ingeniería enfocadas en el diseño de programas y máquinas capaces de realizar tareas para las cuales, los humanos son naturalmente buenos [215]. De acuerdo con Zhang et al. [214], dentro de la inteligencia artificial se pueden encontrar subcategoría entre las que destacan el razonamiento, programación, vida artificial, minería de datos, inteligencia artificial distribuida, comprensión del lenguaje natural, sistemas expertos, redes neuronales, computación evolutiva, teoría de la computación y, por su puesto, el aprendizaje automático.

El aprendizaje automático conforma, precisamente, un área específica dentro de la inteligencia artificial (ver Figura 21). Como se menciona al principio de esta sección, el aprendizaje automático se refiere a la creación de modelos computacionales capaces de aprender tareas específicas con base a experiencia y medidas de desempeño sin ser programados explícitamente [206], [215]. Es decir, dotar a un modelo computacional de un ciclo de retroalimentación que le permita aprender de la experiencia [207], lo que permite a las computadoras encontrar ideas ocultas y patrones complejos [206].

Por su parte, las redes neuronales representan una herramienta dentro del aprendizaje automático y representan la tendencia más popular a la fecha [207], [216]. Este tipo de algoritmos se inspiran en la arquitectura y dinámica de las redes neuronales biológicas, que consiste en representaciones matemáticas de unidades de procesamiento interconectadas llamadas neuronas artificiales [206], cuyo principal fundamento, es el aprendizaje por medio de cambios en la conexiones entre dichas neuronas [216] (ver sección 2.12.2).

De acuerdo con la Figura 21, el aprendizaje profundo constituye un subcampo dentro del aprendizaje automático en el que se aprenden representaciones idóneas

de los datos mediante el uso de capas. Es decir, la palabra “profundo” no se refiere a un nuevo nivel de entendimiento por parte de los modelos de aprendizaje, sino a la idea de una serie de capas de representaciones que aprenden automáticamente con la exposición a los datos de entrenamiento [217].

La minería de datos y el aprendizaje automático se encuentran estrechamente relacionados, pues la minería de datos hace uso de algoritmos de aprendizaje automático para examinar grandes bases de datos y descubrir conocimiento oculto en dichos datos. Por otra parte, el aprendizaje automático emplea métodos de minería de datos para procesar datos antes de aprender tareas específicas [212].

2.9.1 Elementos en un problema de aprendizaje automático

En lo que se conoce como programación clásica, los productos de software son programados explícitamente [207]. Esto significa que el programa fue escrito como un algoritmo, una serie de reglas que procesan los datos y da una respuesta como salida [217], [218] (ver Figura 22). La programación clásica es la columna vertebral de la computación actual. Es ideal en la administración de datos o el cálculo de valores. Sin embargo, se limita al nivel de abstracción de sus programadores pues la programación clásica requiere tener en cuenta cada posible contingencia y los humanos tienden a dar muchas cosas por sentido [207].

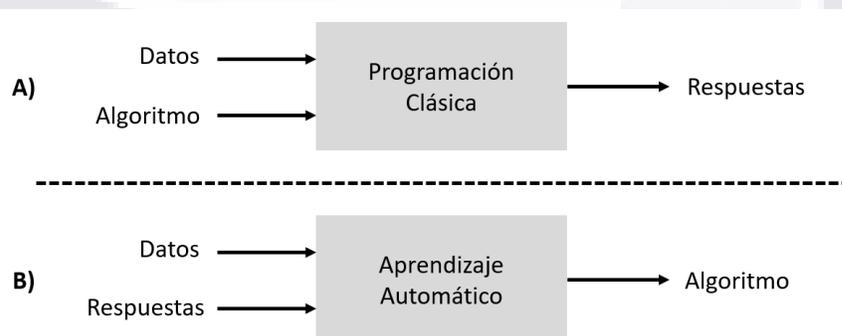


Figura 22. Contraste entre programación clásica y el aprendizaje automático. Basado en los diagramas publicados en [207], [217], [218].

A diferencia de los sistemas de programación clásica, encargados de ejecutar una misma operación, los sistemas de aprendizaje automático extraen automáticamente información relevante de los datos y las respuestas esperadas que procesan. Es decir, con aprendizaje automático los productos de software son entrenados en lugar de ser explícitamente programados [217]. Como se observa en la Figura 22, un sistema de aprendizaje automático es alimentado con datos y respuestas, esto es, ejemplos relevantes de la tarea asignada. El sistema encontrará la estructura adecuada y dará como resultado el algoritmo con las reglas que describen la relación entre los datos y las respuestas [217], [218].

Con base a lo anterior, y de acuerdo con Moreno et al. en [219], el modelo de aprendizaje automático esta dado por:

$$\text{Aprendizaje} = \text{Selección} + \text{Adaptación} \quad (3)$$

De esta manera, el sistema aprendizaje automático selecciona las características más relevantes de un evento u objeto y las contrasta con otras conocidas, si existen. Por otro lado, si dichas diferencias son significativas, las adapta al modelo del evento (u objeto). Finalmente, este proceso se traduce en la mejora en la calidad de actuación del sistema.

El aprendizaje automático puede ser implementado en infinitos casos de uso, sin embargo, cada uno resulta diferente. El autor Alan Norman [207] destaca cinco elementos centrales presentes en cualquier aplicación de aprendizaje automático:

1. **Problema:** la utilidad del aprendizaje automático se centra en problemas de reconocimiento de patrones y la predicción de comportamientos basados en datos históricos. Un sistema de aprendizaje automático requiere de una correcta definición del problema, donde se especifica a la máquina qué buscar con una retroalimentación adecuada, para garantizar los resultados deseados. Cada proyecto de aprendizaje automático posee su propio contexto específico, por lo que aplicar a un problema diferente requerirá un nuevo enfoque y, posiblemente, un algoritmo diferente.

2. **Datos:** Elemento central para el aprendizaje automático, pues la calidad de los resultados son el reflejo directo de la calidad de los datos con los que se alimenta un modelo de aprendizaje automático. Por ello, es importante tomar precauciones como:
 - a. Los datos deben provenir de muestras aleatorias.
 - b. El tamaño de la muestra debe ser lo suficientemente grande para obtener conclusiones significativas con un alto nivel de confianza.
 - c. Los datos deben etiquetarse y limpiarse para evitar datos erróneos.

La presencia de datos erróneos o incompletos pueden causar la inutilidad de un modelo de aprendizaje automático.

3. **Algoritmos:** Se considera el componente principal al hacer referencia al aprendizaje automático. En la literatura es posible encontrar algoritmos de aprendizaje automático bien establecidos basados en estadística y matemáticas para sustentar sus resultados. Por ejemplo, se hace uso del análisis de datos topológicos, métodos de optimización, estrategias de reducción de dimensionalidad, geometría diferencial computacional y ecuaciones diferenciales.

Los algoritmos de aprendizaje se componen de entradas (datos), vectores de salida (predicciones) y un proceso de ajuste que corresponde a ciclos de retroalimentación del modelo.

4. **Entrenamiento:** Es la etapa en la que el modelo de aprendizaje realmente aprende. Es un proceso en el que se buscan correlaciones entre los datos proporcionados y que puede resultar intensivo requiriendo tiempo y procesamiento considerable para obtener los resultados deseados.
5. **Resultados:** Se trata del paso final, donde los modelos de aprendizaje automático cumplen el objetivo de proporcionar datos útiles. Los resultados deben ser accesibles al público final y deben responder al contexto y el problema que se aborda.

2.9.2 Tipos de aprendizaje automático

De acuerdo con la manera en que un sistema realiza el proceso de selección y adaptación sobre la información, es posible identificar distintos tipos de aprendizaje automático: inductivo y deductivo [219].

El aprendizaje inductivo se trata del tipo de aprendizaje más estudiado dentro del aprendizaje automático. En el aprendizaje inductivo no se cuenta con información de dominio sobre los objetos a tratar [219]. Es decir, “*se basa en el descubrimiento de patrones a partir de ejemplos*” [220]. De esta manera, se crean herramientas que permiten predecir comportamientos futuros a partir de los observados en el pasado.

Desde el punto de vista de la clasificación, las observaciones o comportamiento del pasado (conjunto de entrenamiento) se pueden representar como tablas atributo-valor donde se cuenta con N observaciones, $\{e_1, \dots, e_N\}$, definidas por medio de m atributos o propiedades $e_i = \{p_{i1}, \dots, p_{im}\}$, con un atributo especial que denota la clase o el resultado de la observación C_i . A partir de lo anterior, la tarea del aprendizaje automático inductivo es encontrar un mecanismo que permita inferir la clase de problemas nuevos y similares, de los cuales, se conocen sus atributos, pero no su clase [220], [221].

Cabe destacar que no todas las tareas de clasificación pueden resolverse mediante aprendizaje inductivo, pues se requieren de los siguientes elementos imprescindibles [221]:

- Descripción valor-atributo
- Clases predefinidas.
- Clases discretas.
- Datos suficientes.

Finalmente, el aprendizaje inductivo es aplicado en distintas tareas de clasificación como la previsión, por ejemplo, la predicción del desempeño de un equipo deportivo; la valoración, determinando si se autoriza o no un crédito bancario; el diagnóstico, realizado diagnósticos médicos con base a los estudios

realizados al paciente; y el control de procesos, como la secuenciación de trabajos en un sistema flexible de fabricación [221].

Para visualizar la diferencia entre el aprendizaje inductivo y el deductivo, se dice que el primero va de lo individual a lo general, mientras que el segundo va de lo general a lo particular. Específicamente, el aprendizaje deductivo *“inicia con un enunciado o hipótesis y examina las posibilidades de alcanzar una específica y lógica conclusión”* [222]. Esto es, la deducción comienza con un hecho conocido, por ejemplo, “todos los peces tienen branquias”. A este hecho se agrega un hecho probado como: “la barracuda es un pez”. La tercera, y última, declaración requiere que las dos anteriores sean verdaderas. Así, si una o ambas declaraciones son falsas, la tercera declaración también es falsa. En este ejemplo, una tercera declaración sería “la barracuda tiene branquias” la cual, es verdadera al ser verdaderas las primeras afirmaciones [223].

2.9.3 Clasificación de algoritmos de aprendizaje automático

Los algoritmos de aprendizaje automático pueden clasificarse con respecto a la naturaleza de los datos como aprendizaje supervisado, no supervisado y semi supervisado como se muestra en la Figura 23.

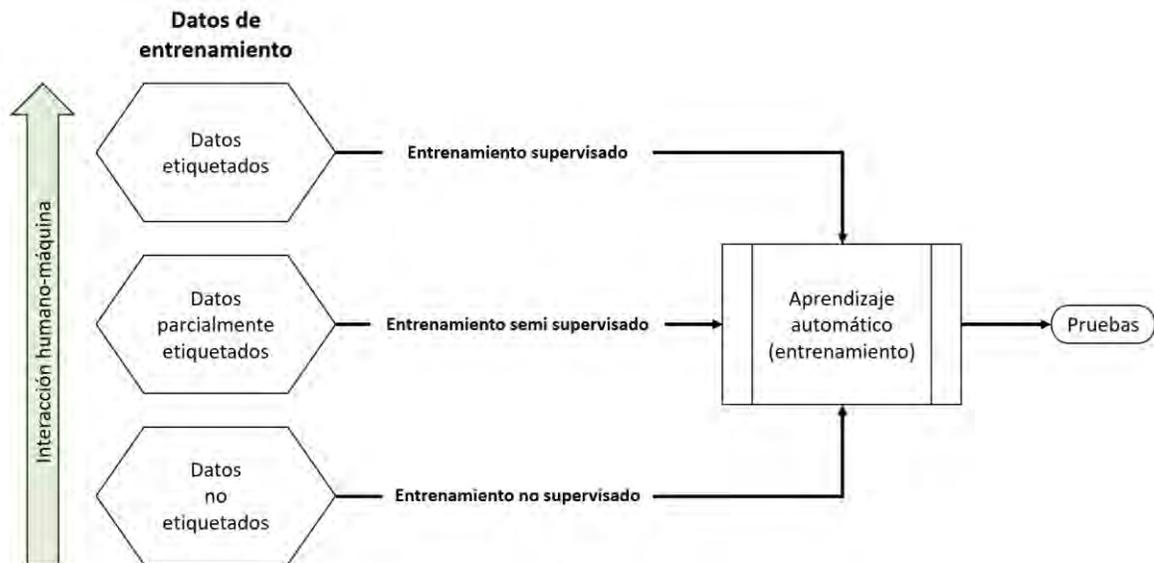


Figura 23. Categorías de los algoritmos de aprendizaje automático según la naturaleza de los datos de entrenamiento. Obtenida de [212].

El aprendizaje supervisado parte de un conjunto de datos inicial (conjunto de entrenamiento) para el cual, se conocen sus valores objetivo (clasificación o regresión) para una serie de eventos u objetos a partir de los cuales, se construye un modelo de predicción que permite predecir los resultados de nuevas instancias (ver Figura 23) [19], [208], [224], [225]. Es decir, en el aprendizaje supervisado, el modelo matemático subyacente aprende de sus parámetros a partir de las muestras etiquetadas (datos de entrenamiento) para luego, hacer predicciones con muestras que el modelo no conoce (datos de prueba).

El aprendizaje supervisado (Figura 24) constituye el enfoque más utilizado y entendido en el campo del aprendizaje automático [207], pues la mayoría de las aplicaciones de aprendizaje automático implican un proceso de supervisión [226].

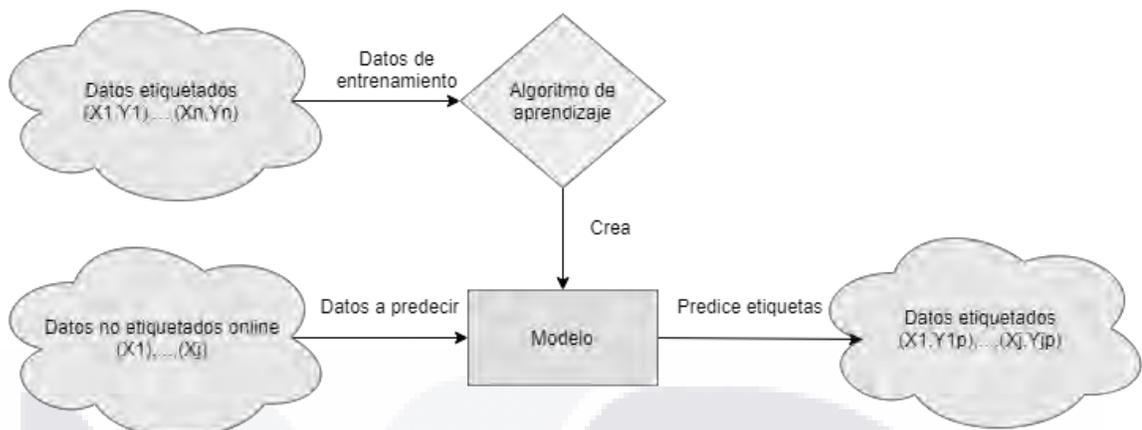


Figura 24. Aprendizaje supervisado. Obtenida de [227].

Por otro lado, el aprendizaje no supervisado parte de un conjunto de datos inicial (conjunto de entrenamiento) sin conocimiento de sus valores objetivo (clases). El objetivo es modelar la estructura o distribución de los datos para aprender sobre ellos [208], [227] (Ver Figura 25).



Figura 25. Aprendizaje no supervisado. Traducido y adaptado del original publicado en [228].

Dado el hecho de que este enfoque involucra datos no etiquetados, se podría argumentar que no existe aprendizaje automático al no existir conocimiento para aprender. Sin embargo, el aprendizaje no supervisado trata de encontrar (aprender) estructuras, tendencias o distribuciones subyacentes en los datos de entrenamiento [207], [226].

El aprendizaje semi supervisado es una combinación entre el aprendizaje supervisado y el no supervisado. Se aplica cuando el conjunto de datos esta parcialmente etiquetado donde, la parte etiquetada es utilizada para inferir la parte no etiquetada [212].

Como se puede observar en la Figura 26, cada enfoque del aprendizaje automático está dirigido a una serie de problemas específicos. Por ejemplo, para el caso del aprendizaje supervisado, se tiene la clasificación donde requiere de muestras con una etiqueta de clase, En adición, el aprendizaje supervisado también aborda el problema de regresión, donde se necesitan muestras con el valor de salida deseado para cada una [226]. Por su parte, el aprendizaje no supervisado se enfoca en problemas de agrupamiento, donde el conjunto de datos se organiza en subgrupos que comparten características similares y, además, es posible utilizarse en problemas de asociación cuyo objetivo es obtener la correlación que existe entre las variables [207].

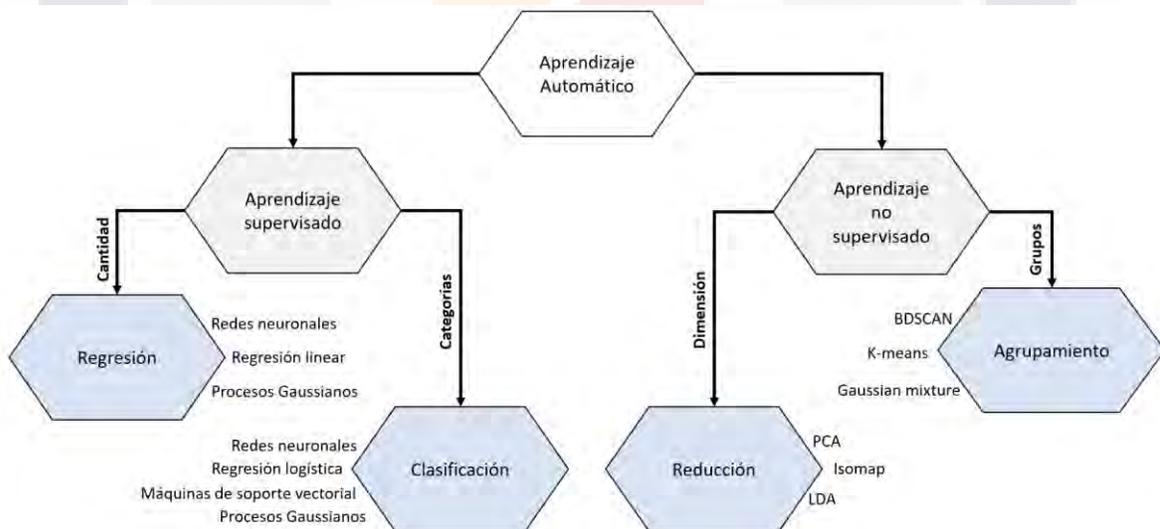


Figura 26. Enfoques y aplicaciones del aprendizaje automático. Obtenida de [214].

En las secciones 2.10 y 2.11 se abordan, con mayor detalle, los problemas de *regresión* y *clasificación* respectivamente.

2.10 Regresión

Los algoritmos o sistemas de aprendizaje pueden realizar dos grandes tareas: la regresión y la clasificación [224]. La diferencia radica en el resultado obtenido al aplicar alguna de las dos tareas [229]. Esta sección se enfoca en la regresión cuyo objetivo es la predicción de un valor continuo en función de las entradas de un modelo cuya respuesta puede determinar una relación lineal entre los atributos [230]. De manera formal, un modelo de regresión representa la relación entre variables independientes $[x_1, \dots, x_k]$ y una variable dependiente y . Dicho modelo permite explicar y predecir el comportamiento de dicha relación [231], [232], *“asumiendo el supuesto de causalidad en las variables analizadas, sin poder demostrarlo; sabiendo esto, entonces, con el modelo adecuado, se pueden realizar estimaciones sobre la variable y a partir del conjunto de variables X ”* [232].

De acuerdo con lo anterior, los objetivos de la construcción de modelos de regresión son [231]:

- Evaluar el efecto del cambio en características determinadas sobre una característica en concreto.
- Estimar el valor de la característica dependiente en función de los valores que las características independientes pueden tomar.

Los modelos de regresión se pueden expresar de la siguiente forma:

$$y = \beta_0 + \beta_1^T x + \varepsilon_i \quad (4)$$

Donde:

$$\beta_1 = [\beta_1, \beta_2, \dots, \beta_k]^T$$

$$x = [x_1, x_2, \dots, x_k]^T$$

La ecuación 4 es la expresión de la aproximación de la relación entre las variables x y y [233]. Donde y es la variable por estimar, mientras que x son las *variables* predictoras o independientes. Por su parte, β_0 es la ordenada al origen en el plano

de regresión, mientras que $\beta_{i=1,\dots,i=k}$, es el parámetro que miden la influencia de las variables independientes en el valor que toma y [232], [233]. Finalmente, ε es el error del modelo cuyo valor es el mínimo comparado con otros posibles modelos.

Al predecir la variable y a partir de las variables x , el modelo de regresión de la ecuación 4 representa la relación entre las variables, que puede ser simple, si $k = 1$; o múltiple si $k > 1$. Además, puede ser lineal o no lineal de acuerdo con los exponentes de las variables en el modelo [232].

Las premisas de los modelos de regresión son los siguientes:

- *“La relación entre la respuesta y y los regresores es lineal, al menos en forma aproximada.*
- *El término del error ε tiene media cero.*
- *El término del error ε tiene varianza σ^2 constante.*
- *Los errores no están correlacionados.*
- *Los errores tienen una distribución normal.”* [232], [234].

2.11 Clasificación

A diferencia de la regresión, la clasificación tiene como objetivo predecir una etiqueta discreta (en lugar de un valor continuo) a un objeto u observación, dentro de un conjunto finito de posibles resultados [230], [235]. Por ejemplo, si un correo es spam o no, tipo de tumor (benigno o maligno), si una mascota es perro o gato, etc. [229]

De acuerdo con el número de clases con las que se trabaja, se tienen dos tipos de clasificaciones [236]:

- **Clasificación binaria:** En este caso solo existen dos clases a asignar (0 o 1, verdadero o falso).

- **Clasificación Multiclase:** En este tipo de clasificación existen más de dos categorías posibles para asignar a las observaciones. Por ejemplo, el reconocimiento de caracteres manualmente escritos (a-z).

2.11.1 Evaluación de un modelo de clasificación

La evaluación de un modelo de aprendizaje automático determina la capacidad de éste para la predicción de nuevas y futuras instancias [237]. El objetivo es maximizar la capacidad de generalización del modelo. Para ello, el conjunto de datos se divide en un conjunto de entrenamiento y un conjunto de validación [218], como se muestra en la Figura 27. Este punto es importante, pues evaluar el modelo con datos que ya conoce no es útil, pues no se busca la capacidad de “recordar” [237]. El objetivo es evitar que los modelos de aprendizaje se sobreajusten, es decir, “*el modelo se ha vuelto demasiado específico para los datos en los que fue entrenado y no predice tendencias o clasificaciones generales en el mundo real*” [207]. El sobreajuste es un fenómeno que ocurre cuando los modelos son capaces de hacer buenas predicciones dentro de la muestra de aprendizaje, pero su desempeño es muy pobre con datos que el modelo desconocía [238].



Figura 27. División de datos simple para un modelo de aprendizaje automático. Obtenida de [217].

Para evaluar el desempeño de un modelo o sistema de aprendizaje se cuenta con una herramienta conocida como matriz de confusión. La matriz de confusión (ver Tabla 2) contiene la información acerca de las predicciones realizadas por el sistema de aprendizaje comparando la clase real en el conjunto de datos de aprendizaje o prueba contra la predicción del sistema [239].

Tabla 2. Matriz de confusión [240].

		Predicción	
		Negativo	Positivo
Real	Negativo	<i>TN</i>	<i>FP</i>
	Positivo	<i>FN</i>	<i>TP</i>

Donde:

- **TN:** Verdaderos negativos
- **FP:** Falsos positivos
- **FN:** Falsos negativos
- **TP:** Verdaderos positivos

A partir de los elementos de la matriz de confusión es posible calcular métricas que permiten evaluar el desempeño del sistema [240], [241]:

- **Exactitud (AC, accuracy):** Proporción del total de predicciones correctas.

$$AC = \frac{TN + TP}{TN + FP + FN + TP} \quad (5)$$

- **Precisión positiva (TPrate, true positive rate):** Proporción de casos positivos correctamente clasificados.

$$TPrate = \frac{TP}{FN + TP} \quad (6)$$

- **Precisión negativa (TNrate, true negative rate):** Proporción de casos negativos correctamente clasificados.

$$TNrate = \frac{TN}{TN + FP} \quad (7)$$

- **Razón de falsos positivos (FPrate, false positive rate):** Proporción de casos negativos clasificados como positivos.

$$FPrate = \frac{FP}{TN + FP} \quad (8)$$

- **Razón de falsos negativos (FNrate, false negative rate):** Proporción de casos positivos clasificados como negativos.

$$FNrate = \frac{FN}{FN + TP} \quad (9)$$

2.12 Modelos de Clasificación

2.12.1 Naive Bayes (NBC)

Las redes bayesianas, los árboles de decisión y las redes neuronales artificiales han sido los métodos más utilizados en aprendizaje automático en tareas de clasificación [210], [242]. El clasificador bayesiano simple (naive Bayes classifier, NBC) forma parte del modelado probabilístico, el cual aplica principios estadísticos para el análisis de datos [217]. Naive Bayes es el clasificador más simple en aprendizaje supervisado. Se basa en el teorema de Bayes de la Ecuación 10 y en la premisa de independencia de los atributos dada una clase [243] (*“una fuerte o ‘ingenua’ (‘naive’) suposición, que es de donde viene su nombre”*) [217].

$$P(C_i | E) = \frac{P(C_i)P(E|C_i)}{P(E)} \quad (10)$$

Donde C_i (efecto) es la clase y E es un vector de atributos conocidos A_1, A_2, \dots, A_m (causas). El teorema de Bayes y su fundamentación datan del siglo XVIII y éste ha permitido el análisis de datos mucho antes de su implementación por computadora [217]. Otra ventaja importante, es el hecho de que este modelo tiene la capacidad de trabajar con datos omitidos sin la necesidad de sustituirlos con alguna estimación [226], es decir, tiene poca sensibilidad a las variaciones de ruido en el conjunto de entrada [211].

Dado que el NBC asume que los atributos son independientes entre sí dada la clase, la probabilidad se obtiene como por el producto de las probabilidades condicionales individuales de cada atributo dado el nodo clase, tal como se muestra en la Ecuación 11 [244]:

$$P(C_i | E) = \frac{P(C_i)P(E_1|C_i)P(E_2|C_i) \dots P(E_m|C_i)}{P(E)}, \quad (11)$$

$m = \text{número de atributos}$

De manera gráfica, un NBC puede representarse como una red bayesiana con forma de estrella (Figura 28), “con un nodo raíz, C , que corresponde a la variable de la clase conectada, a su vez, con los atributos A_1, A_2, \dots, A_n . Los atributos son condicionalmente independientes dada la clase, de forma que no existen arcos entre ellas” [245].

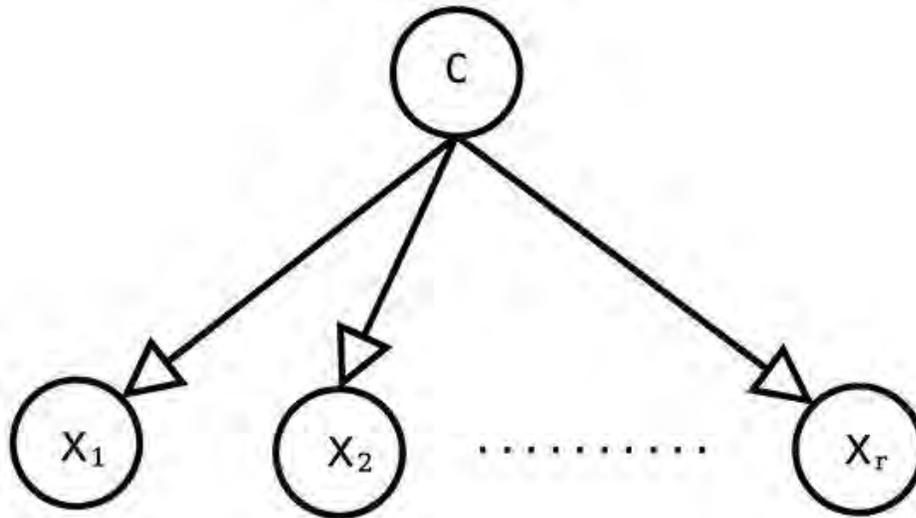


Figura 28. Clasificador bayesiano simple. Obtenida de [244], [246].

Construcción de un clasificador bayesiano simple

La estructura del NBC está predeterminada, por lo que solo requiere de los siguientes parámetros [244]:

$P(C)$: Vector de probabilidades a priori para cada clase.

$P(E_i|C)$: Matriz de probabilidad condicional para cada atributo dada la clase.

Partiendo de lo anterior, la construcción de un clasificador naive Bayes consiste en [244], [246]:

- Un conjunto de datos D .

- Asumir que se busca predecir la variable y , la cual puede asumir n_y valores distintos: v_1, v_2, \dots, v_n .
- Asumir la existencia de m atributos de entrada, x_1, x_2, \dots, x_m .
- Dividir D en n_y grupos, es decir, separar por clases: $D_{si} =$ conjunto de registros para $y = v_i$
- Para cada D_{si} se utiliza estimación de densidad para estimar el modelo M_i que modela la distribución de las variables de entrada entre los registros.
- Predecir la clase $y = v_i$ para la cual, la probabilidad posterior $P(y = v_i | x_1 = v_1, x_2 = v_2, \dots, x_m = v_m)$ sea la mayor posible:

$$y_p = \arg \max (P(y = v_i | x_1 = v_1, x_2 = v_2, \dots, x_m = v_m)) \quad (12)$$

- Recordando el teorema de Bayes, en el que los atributos son independientes dada la clase, el valor de la clase predicha se puede expresar como:

$$y_p = \arg \max \left(P(y) \prod_{j=1}^m P(x_j = v_j | y = v_i) \right) \quad (13)$$

El NBC debe su éxito a su simplicidad, pues no requiere de estructurar una red bayesiana pues su estructura es fija y los parámetros del modelo son estimados desde el conjunto de datos usando estadísticos bidimensionales para la clase y cada atributo [246].

2.12.2 Redes neuronales artificiales

Las redes neuronales artificiales (RNA o ANN, artificial neural networks) representan un importante marco de trabajo para la implementación del aprendizaje automático y, especialmente, en aprendizaje profundo (deep learning) [247] con una amplia gama de aplicaciones en diferentes campos como la computación, ciencia, ingeniería, medicina, agricultura, negocios, artes, etc. Así, los modelos de RNA son populares en tareas de clasificación, agrupamiento, reconocimiento de patrones y predicción en diferentes disciplinas [248], [249].

Recientemente, los modelos de RNA ha tenido un impacto significativo en la automatización organizacional y procesos comerciales, mejorando la extracción automática de información, reconocimiento, previsión y optimización [250]. Entre las aplicaciones modernas más destables se encuentra la seguridad de datos, predicción de mercados, diagnósticos médicos, detección de fraudes, procesamiento del lenguaje natural, asistentes virtuales, vehículos inteligentes, control de calidad y visión artificial [247], [251]–[253].

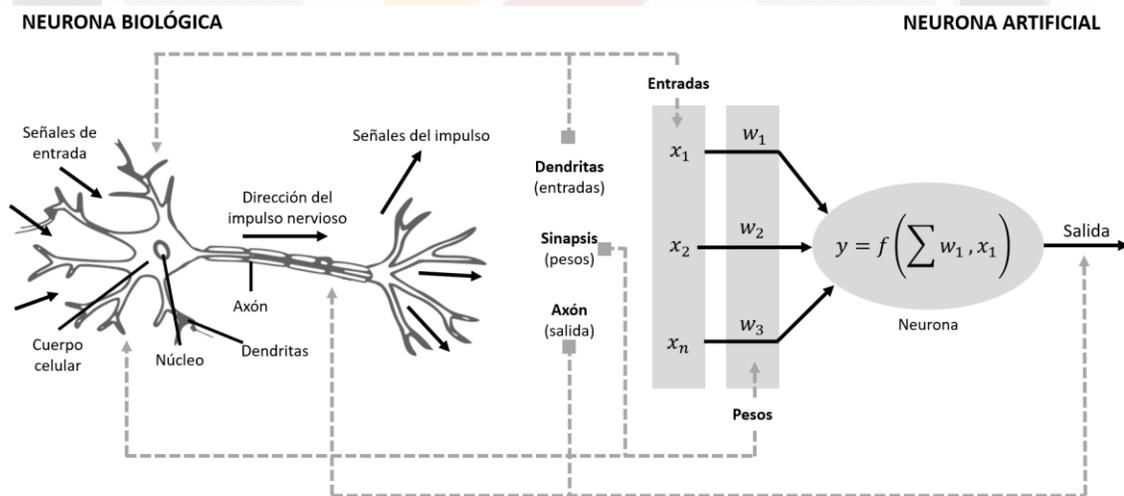


Figura 29. Comparación entre una neurona biológica (izquierda) y una neurona artificial (derecha). Réplica basada en la publicada por [86].

De acuerdo con Mitchell [210], “los métodos de aprendizaje de redes neuronales proporcionan un enfoque sólido para aproximar funciones objetivo de valores reales,

valores discretos y vectores". Es decir, son sistemas de aprendizaje inspirados en la arquitectura y dinámica del cerebro humano que permiten establecer relaciones no lineales entre variables de entrada y salida [216], [254], como se aprecia en la Figura 29.

Por su parte, Asanza et al. [255] describen a las redes neuronales artificiales como una familia de técnicas para el procesamiento de información inspiradas en el procesamiento biológico de información realizado por las neuronas en el sistema nervioso de los seres vivos. Esto es, *"las redes neuronales artificiales son modelos de datos estadísticos no lineales que reproducen el comportamiento de las redes neuronales biológicas"* [256]. Incluso, características como la no linealidad, robustez, alto paralelismo, tolerancia a fallos, aprendizaje, manejo de información imprecisa y difusa, y la capacidad de generalización, son heredados de la contraparte biológica [257].

Las redes neuronales poseen características que asemejan el funcionamiento de la clasificación realizada por los humanos, pues poseen la capacidad de cambiar las conexiones entre sus neuronas [216]. Gracias a su constitución y a sus fundamentos, son capaces de aprender con a base a la obtención de experiencia, generalizando casos y abstrayendo características esenciales. De esta manera, las RNA ofrecen ventajas importantes, entre las que se incluyen [258]:

- **Aprendizaje adaptativo:** Aprenden tareas con base a un entrenamiento o experiencia inicial.
- **Autoorganización:** Tienen la capacidad de crear su propia representación de la información que reciben durante el aprendizaje.
- **Tolerancia a fallos:** Algunas capacidades de las redes pueden prevalecer a pesar de ruido, distorsiones o faltantes en los datos.
- **Operación en tiempo real:** Las operaciones de una red pueden llevarse a cabo en paralelo.
- **Fácil inserción dentro de la tecnología existente:** Se pueden integrar a sistemas existentes para mejorar su capacidad en ciertas tareas.

De acuerdo con la salida de las neuronas artificiales, se pueden clasificar en [258]:

- **Neuronas binarias:** Solamente pueden tomar valores dentro de los intervalos $\{0,1\}$ o $\{-1,1\}$.
- **Neuronas reales:** Toman valores dentro del rango $[0,1]$ o $[-1,1]$

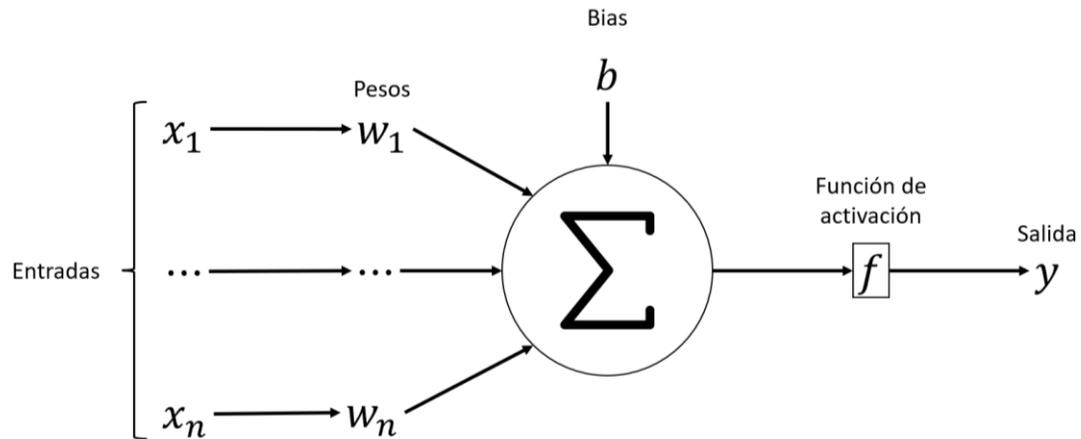


Figura 30. Neurona artificial. Obtenida de [259].

En la Figura 29 se muestra la analogía entre una neurona biológica y una neurona artificial, como unidades de procesamiento en ambos modelos [249]. Mientras que la Figura 30 muestra una neurona artificial que recibe diferentes entradas, representadas por x_i , las cuales son multiplicadas por un peso w_i , cuyo valor puede modificarse para adaptarse a una tarea determinada [260]. Cada uno de estos productos es sumado, junto con un sesgo aprendido conocido como bias (b). Dicha suma tiene una función de activación aplicada como $y = f(\sigma)$, donde σ es la suma ponderada y el sesgo, mientras que y , es la salida de la neurona [261]. Así pues, la salida de una neurona artificial está dado por la función de activación de la suma de los productos ponderados de las entradas y sus pesos, más el sesgo [210], [258], [261], [262]; tal como se muestra en la ecuación 14.

$$y = f\left(\sum_{i=1}^n (x_i w_i) + b\right) \tag{14}$$

Al igual que las neuronas biológicas, las neuronas artificiales poseen dos estados: uno de activación y otro de inactivación. La diferencia, radica en que las neuronas artificiales pueden tener más de dos estados de activación dentro de un conjunto determinado. Para determinar el estado de una neurona artificial se hace uso de la función de activación [258].

La función de activación opera en la combinación lineal de las entradas y el sesgo $\sigma = \sum_{i=1}^n (x_i w_i) + b$. Ésta función puede ser cualquiera con una salida [261] y se elige de acuerdo con la tarea que realiza la neurona [260]. Las funciones de activación más comunes se muestran en la Figura 31.

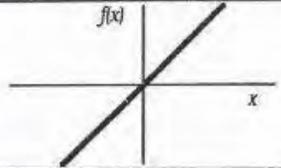
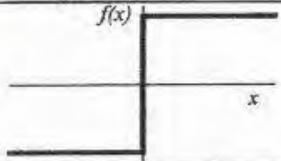
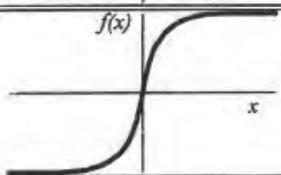
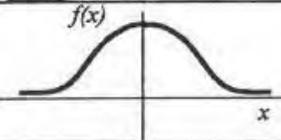
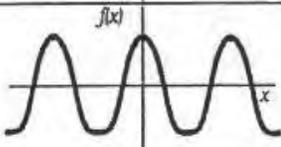
	Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, +\infty]$	
Escalón	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
Sigmoidea	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
Gaussiana	$y = Ae^{-Bx^2}$	$[0, +1]$	
Sinusoidal	$y = A \text{sen}(\omega x + \varphi)$	$[-1, +1]$	

Figura 31. Funciones de activación más comunes [258], [260].

Es importante tener en cuenta que el propósito principal de las redes neuronales artificiales no es exactamente replicar la manera en que funcionan las redes neuronales biológicas. Sin embargo, abstraen procesos como la recepción, procesamiento y comunicación de información entre las neuronas biológicas [257]. Así, las redes neuronales artificiales son una representación matemática de la arquitectura neuronal humana que refleja capacidades de “aprendizaje” y “generalización” [263].

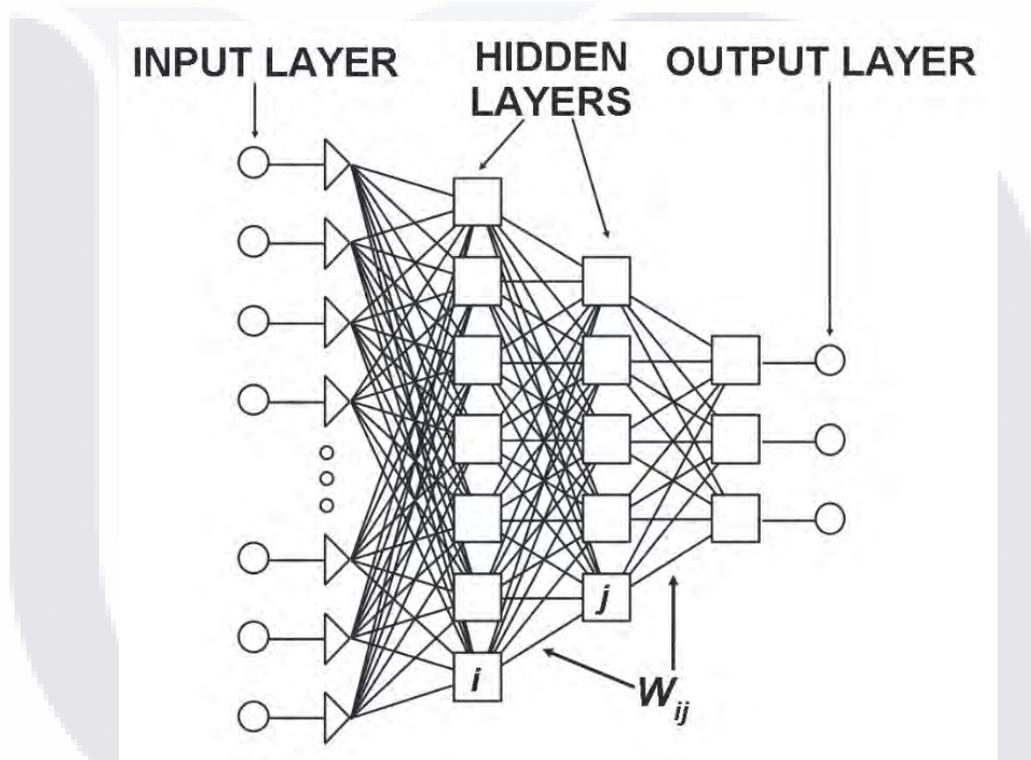


Figura 32. Red neuronal artificial. Obtenida de [263].

La Figura 32 muestra una red neuronal artificial como un conjunto de neuronas artificiales organizadas en capas, donde cada neurona posee un número determinado de conexiones de entrada-salida hacia otras neuronas [263]. Como se puede observar, la red neuronal tiene una capa de entrada donde se reciben los datos. Estos datos son transferidos a una o más capas ocultas, que son las responsables del procesamiento matemático de la información multiplicando el valor de entrada por un peso W , como se muestra en la Figura 32. El resultado obtenido

es propagado hacia las neuronas de las siguientes capas para que, finalmente, la capa de “salida” provea el resultado de la red [263], [264].

Cada capa en una red neuronal artificial es independiente al resto, esto es, una capa en particular puede tener un número específico de neuronas artificiales [249], [263]. Sin embargo, el número de capas, así como el número de neuronas en cada una, depende completamente del problema a resolver [263]. Por ejemplo, para un clasificador las neuronas de entrada y salida corresponden a los atributos de entrada y a las clases involucradas respectivamente [249].

Como se mencionó en la sección 2.9 y observando la Figura 21, el aprendizaje profundo (deep learning) forma parte del campo del aprendizaje automático en el área de inteligencia artificial [217], [259]. Donde el término “profundo” hace referencia a la idea de capas sucesivas de representaciones, normalmente más de dos [265]. Donde estas capas de representaciones son aprendidas, en la mayoría de los casos, por redes neuronales estructuradas en capas colocadas en secuencia una seguida de otra [217]. Una red neuronal artificial con mayor número de capas ocultas posee una mayor capacidad de extracción de características [266]. Es decir, el aprendizaje profundo es motivado por los teoremas del aproximador universal, donde se afirma que redes neuronales lo suficientemente profundas y amplias pueden aproximar funciones con precisión arbitraria [267].

El aprendizaje profundo representa uno de los grandes avances en las últimas décadas en el campo del aprendizaje automático como algoritmos sofisticados de aprendizaje y técnicas de preprocesamiento [206]. Este paradigma ha logrado desempeños superhumanos en clasificación de imágenes, juegos, análisis médicos, razonamiento relacional, reconocimiento de voz, etc., gracias al crecimiento exponencial de capacidad de cálculo y de la disponibilidad generalizada de datos [267].

A la fecha, se han propuesto en la literatura diferentes arquitecturas de redes neuronales profundas, donde algunos de los enfoques más comunes se muestran en la Figura 33.

Finalmente, las redes neuronales artificiales han conseguido una gran aceptación debido a su capacidad de proporcionar modelos sencillos de usar con soluciones precisas para problemas complejos reales en un sinnúmero de aplicaciones a través del modelado de “*sistemas altamente no lineas en los que la relación entre las variables es desconocida o muy compleja*” [249], [257], [263].



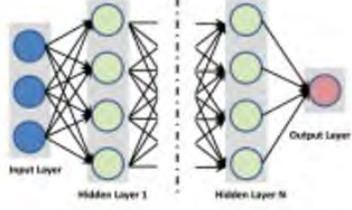
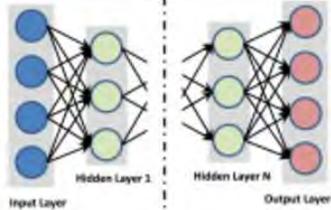
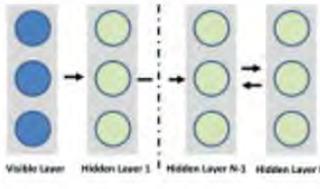
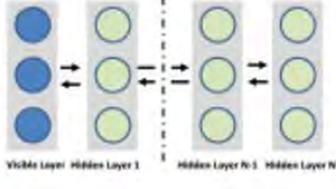
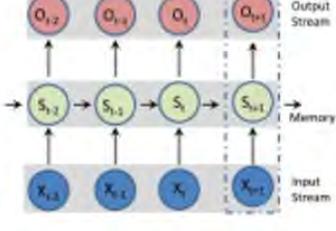
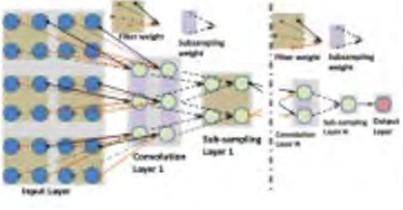
Architecture	Description	Key Points
	<p>Deep Neural Network</p> <ul style="list-style-type: none"> • General deep framework usually used for classification or regression • Made of many hidden layers (more than 2) • Allows complex (non-linear) hypotheses to be expressed 	<p>Pros:</p> <ul style="list-style-type: none"> • Widely used with successes in many areas <p>Cons:</p> <ul style="list-style-type: none"> • Training is not trivial because once the errors are back-propagated to the first few layers they become minuscule • The learning process can be very slow
	<p>Deep Autoencoder</p> <ul style="list-style-type: none"> • Proposed in [5] and is mainly designed for feature extraction or dimensionality reduction • Has the same number of input and output nodes • Aims to recreate the input vector • Unsupervised learning method 	<p>Pros:</p> <ul style="list-style-type: none"> • Does not require labelled data for training • Many variations have been proposed to make the representation more robust: Sparse AutEnc. [6], Denoising AutEnc. [7], Contractive AutEnc. [8], Convolutional AutEnc. [9] <p>Cons:</p> <ul style="list-style-type: none"> • Requires a pre-training stage • Training can also suffer from vanishing of the errors
	<p>Deep Belief Network</p> <ul style="list-style-type: none"> • Proposed in [10] is a composition of RBM where each sub-network's hidden layer serves as the visible layer for the next • Has undirected connections just at the top two layers • Allows unsupervised and supervised training of the network 	<p>Pros:</p> <ul style="list-style-type: none"> • Proposes a layer-by-layer greedy learning strategy to initialize the network • Inferences tractable maximizing the likelihood directly <p>Cons:</p> <ul style="list-style-type: none"> • Training procedure is computationally expensive due to the initialization process and sampling
	<p>Deep Boltzmann Machine</p> <ul style="list-style-type: none"> • Proposed in [11] is another approach based on the Boltzmann family • Possesses undirected connections (conditionally independent) between all layers of the network • Uses a stochastic maximum likelihood [12] algorithm to maximize the lower bound of the likelihood 	<p>Pros:</p> <ul style="list-style-type: none"> • Incorporates top-down feedback for a more robust inferences with ambiguous inputs <p>Cons:</p> <ul style="list-style-type: none"> • Time complexity for the inference is higher than DBN • Optimization of the parameters is not practical for large datasets
	<p>Recurrent Neural Network</p> <ul style="list-style-type: none"> • Proposed in [13] is a NN capable of analyzing stream of data • Useful in applications where the output depends on the previous computations • Shares the same weights across all steps 	<p>Pros:</p> <ul style="list-style-type: none"> • Can memorize sequential events • Can model time dependencies • Has shown great success in many Natural Language Processing applications <p>Cons:</p> <ul style="list-style-type: none"> • Learning issues are frequent due to the vanishing gradient and exploding gradient problems
	<p>Convolutional Neural Network</p> <ul style="list-style-type: none"> • Proposed in [14], it is well suited for 2D data such as images • Every hidden convolutional filter transforms its input to a 3D output volume of neuron activations • Inspired by the neurobiological model of the visual cortex [15] 	<p>Pros:</p> <ul style="list-style-type: none"> • Few neuron connections required with respect to a typical NN • Many variants have been proposed: AlexNet [16], Clarifai [17], and GoogLeNet [18] <p>Cons:</p> <ul style="list-style-type: none"> • It may require many layers to find an entire hierarchy of visual features • It usually requires a large dataset of labelled images

Figura 33. Arquitecturas de deep learning más comunes. Obtenida de [265].

2.12.3 Máquinas de soporte vectorial

Las máquinas de soporte vectorial (SVM, por support vector machines) tienen su origen en los trabajos de Vapnik et al en 1999 [268]. Originalmente, las SVM fueron desarrolladas con el objetivo de resolver problemas de clasificación binaria, aunque en la actualidad han evolucionado en la resolución de problemas como regresión, agrupamiento y clasificación múltiple. Desde su introducción, las SVM han ganado gran reconocimiento gracias a sus fundamentos teóricos sólidos [269], además de que poseen gran capacidad de generalización de nuevos objetos y de construir complejas funciones no lineales [270].

Las SVM son algoritmos de aprendizaje supervisado que tienen el objetivo de encontrar el hiperplano capaz de separar un conjunto de clases en un espacio extendido por la maximización del margen de clasificación [271]. Las SVM son entrenadas por algoritmos de optimización convexa (resultan en una única solución) y se construyen a partir de una estructura que depende de un subconjunto de vectores de soporte (VS) que facilitan la interpretación del modelo [268].

En los casos más simples, los problemas linealmente separables, existe un hiperplano de separación óptimo que maximiza la distancia entre este y cada grupo de observaciones. Para determinar el grupo al que pertenece una observación específica, se considera el signo de la función que define el hiperplano de separación. Para los problemas no separables linealmente, las observaciones de cada grupo se superponen evitando la posibilidad de trazar un hiperplano que los separe. En este caso, las SVM transforman el espacio original de las observaciones de entrada en otro de mayor dimensión (espacio de características) en la cual, los grupos quedan linealmente separables como en el primer caso. De esta manera, las SVM pueden continuar como un problema linealmente separable. Al final de este procedimiento se aplica una transformación inversa para que el hiperplano de separación lineal se convierta en hiperplano no lineal que separa los grupos de observaciones en espacio original [269], [272].

De acuerdo con González et al. en [268], durante la tarea de clasificación de las SVM se identifican dos fases: la fase de aprendizaje estadístico y la fase de reconocimiento. En la primera de ellas, “se extraen los atributos y características de espacio de entrada y se entrena el clasificador”. Como resultado se obtienen los pesos w y la función discriminante que representa la frontera entre las clases. Ambos se definen a mayor detalle más adelante. En la fase de reconocimiento, el nuevo modelo de clasificación asigna a las nuevas observaciones una de las clases según la similitud de sus características.

Caso linealmente separable (SVM de margen máximo)

Como se mencionó anteriormente, las SVM determinan el hiperplano de separación óptimo (HSO) que permite dividir el conjunto de datos [273], pues, como se muestra en la Figura 34(A), existen infinitos hiperplanos que permiten separar los datos en sus respectivas clases [268], [274].

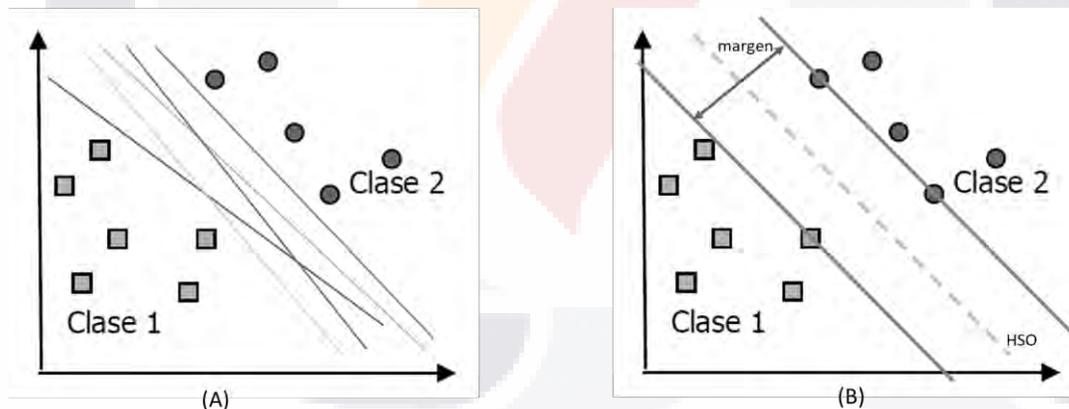


Figura 34. (A) Posibles hiperplanos de separación. (B) Hiperplano de separación óptimo (HSO) [268], [269], [275].

Las SVM comienzan su proceso de entrenamiento con un conjunto $\{(\vec{x}_1, y_1), (\vec{x}_2, y_2), \dots, (\vec{x}_N, y_N)\}$ de N observaciones experimentales, denominado conjunto de entrenamiento. En el conjunto, cada muestra (\vec{x}_i, y_i) está formada por un vector de n características $\vec{x}_i \in \mathbb{R}^n$, que corresponden a las coordenadas

espaciales de cada punto. Asimismo, el conjunto contiene una etiqueta $y_i \in \mathbb{R}$ que determina la *clase* $\{\pm 1\}$ a la que pertenece la muestra [268].

A partir del conjunto de datos, el aprendizaje de las SVM consiste en la construcción del HSO, cuya posición se calcula entre una familia de hiperplanos de la forma [268], [275]:

$$\{\vec{w} \cdot \vec{x} + b = 0\}, \vec{w} \in \mathbb{R}^n, \vec{x}_i \in \mathbb{R}^n, b \in \mathbb{R} \quad (15)$$

Donde la función de decisión está dada por [268], [276]:

$$f(\vec{x}) = \text{sign}(\vec{w} \cdot \vec{x} + b) \begin{cases} 1 & y_i = 1 \\ -1 & y_i = -1 \end{cases} \quad (16)$$

Por lo tanto, para encontrar el HSO en problemas linealmente separables es necesario encontrar el vector \vec{w} de tamaño n y el valor b , tal que el hiperplano clasifique correctamente las muestras \vec{x}_i en dos clases \vec{y}_i [276]. Como se muestra en la Figura 34(B), existen dos hiperplanos que definen la frontera de cada clase: $\vec{w} \cdot \vec{x} + b = 1$ para la *clase positiva* (+) y $\vec{w} \cdot \vec{x} + b = -1$ para la clase negativa; ambos paralelos al HSO dado por $\vec{w} \cdot \vec{x} + b = 0$. El HSO se define por la maximización de la longitud del margen el cual, está dado por la distancia entre los hiperplanos frontera y el HSO [268], donde:

$$\text{margen} = \frac{2}{\|\vec{w}\|} \quad (17)$$

En este punto, el objetivo es solucionar el problema de optimización al buscar maximizar el margen existente entre las clases. Para ello se simplifica por el problema equivalente definido a continuación [274]–[276]:

$$\min(w, b): \frac{1}{2} \|w\|^2, \quad \text{sujeto a: } \sum_i^n \alpha_i y_i = 0, \alpha_i \geq 0 \quad (18)$$

Donde cada α_i es un multiplicador de Lagrange asociados a las restricciones del problema de optimización original. En este caso, aquellos multiplicadores que resultan mayores a 0 son los vectores de soporte, pues son los únicos que influyen en la construcción de HSO [276]. Finalmente, se tiene que para cada vector de soporte se tiene que [269], [276]:

$$w^* = \sum_{i=1}^n \alpha_i^* y_i x_i \quad (19)$$

$$b^* = y_i - w^* \cdot x_i \quad (20)$$

De esta manera, la función de decisión puede expresarse como:

$$f(x) = \text{sign}(w^* \cdot x + b^*) = \text{sign}\left(\sum_{i=1}^m y_i \alpha_i^* (x \cdot x_i) + b^*\right) \quad (21)$$

Caso cuasi-linealmente separable (SVM de margen flexible)

En problemas reales los conjuntos de muestras $\{(\vec{x}_1, y_1), (\vec{x}_2, y_2), \dots, (\vec{x}_N, y_N)\}$ poseen grupos superpuestos en el espacio de entrada que impiden el trazo perfecto del HSO (ver Figura 35) [269], [272] como se muestra en apartado anterior (ver Figura 34). Este tipo de ejemplos se conocen como problemas cuasi-separables [269]. En este caso, es necesario introducir nuevas variables de holgura que permitan el error de clasificación en algunas muestras y a su vez, penalizarlas sin perder el objetivo de encontrar el HSO para el resto de las muestras [269], [272], [273].

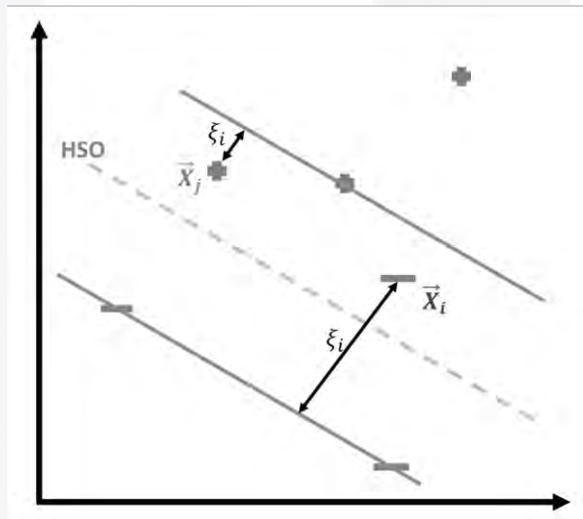


Figura 35. Problema cuasi-separable. Obtenida de [274].

La primera variable de holgura por introducir es el error denotado por ξ_i la cual, permite modelar los errores durante la clasificación al tiempo que los penaliza sin alterar la estructura del HSO [268]. Así, la función de decisión se denota como [269]:

$$y_i(\vec{w} \cdot \vec{x}_i + b) \geq 1 - \xi_i \rightarrow " + ", \xi_i \geq 0, i = 1, \dots, n \quad (22)$$

De esta manera, para una muestra (\vec{x}_i, y_i) , su variable de holgura ξ_i , “representa la desviación del caso separable, medida desde el borde del margen que corresponde a la clase y_i ” [269], tal como se muestra en la Figura 35. Para las

muestras cuyo valor ξ_i sea cero, corresponden a muestras separables; mientras que un valor de ξ_i mayores a cero y menores o iguales a uno corresponden a muestras no separables. Finalmente, para calcular una media del error en la clasificación se puede considerar el término siguiente [275]:

$$error = \sum_{i=1}^N \xi_i \quad (23)$$

Con base a la nueva variable ξ_i , el problema de HSO se redefine como la solución al problema [275]:

$$\min \left\{ \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \right\} \quad (24)$$

$$s. a. y_i(\bar{w} \cdot \bar{x}_i + b) \geq 1 - \xi_i, \xi_i \geq 0, i = 1, \dots, n$$

Donde el valor C es una constante que se define como parámetro de regularización libre en el ajuste de un SVM [269], [275]. Este valor hace un balance entre la maximización del margen y la violación a la clasificación [275]. El valor C requiere un proceso de ajuste por parte del usuario, pues el desempeño del clasificador puede variar dependiendo del comportamiento de los datos de entrenamiento y el valor de C seleccionado [277]. Cuando el valor $C \rightarrow \infty$, se permite un menor número de violaciones en el margen. Incluso, cuando $C = \infty$ no se permiten errores de clasificación haciendo que el SVM se convierta en un modelo de margen máximo descrito en el apartado anterior. Si $C \rightarrow 0$, los errores son menos penalizados y por tanto, más muestras pueden ser mal clasificados [277], [278]. En la práctica el valor de C óptimo puede identificarse mediante validación cruzada [277].

Tomando en cuenta el error ξ_i y el parámetro C , la búsqueda del HSO puede construirse mediante el Lagrangiano:

$$L = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \vec{x}_i \cdot \vec{x}_j \tag{25}$$

$$s. a. \sum_i \alpha_i y_i = 0, 0 \leq \alpha_i \leq C$$

Caso no lineal

Al modelar sucesos reales, es muy probable encontrarse con aquellos que no pueden ser separados linealmente por un hiperplano en \mathbb{R}^n , aún cuando se utilizan las variables de holgura descritas en el apartado anterior, resultado complicado definir el HSO [268] (ver Figura 36A)). Para circunstancias como esta, las SVM extienden la formulación descrita en los apartados anteriores a clasificadores no lineales [273]. Para ello, las SVM no lineales formulan el problema en un espacio de características $\phi(x)$ de una dimensión mayor ($\mathbb{R}^n \rightarrow \mathbb{R}^h$ con $h > n$) mediante la selección y uso de una función kernel [268], [271] (ver Figura 36(B)).

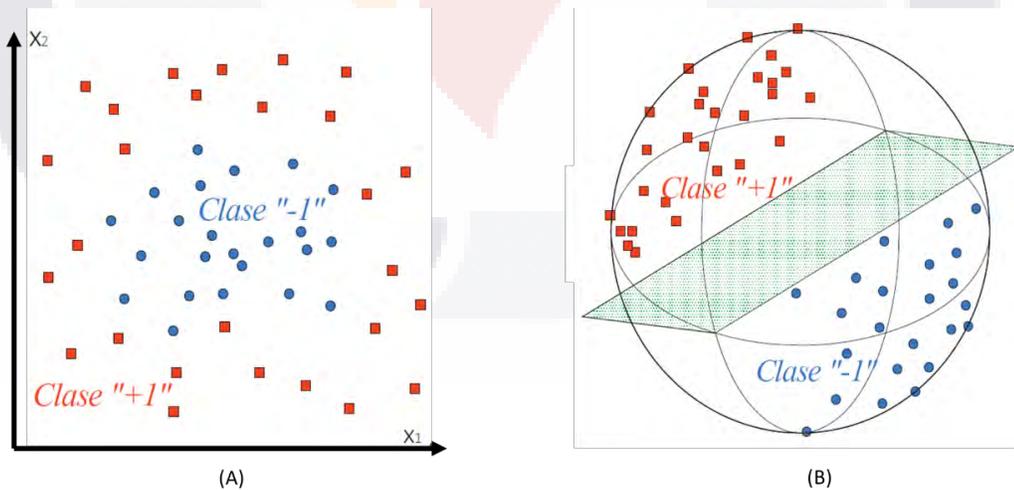


Figura 36. Mapeo de datos. (A) Espacio de entrada. (B) Espacio de características y HSO. Obtenida de [268].

La función kernel representa el producto escalar en el espacio de características, que es un punto en un espacio de características de dimensión arbitraria [279]:

$$K(x_i, x_j) \rightarrow \phi(x_i) \cdot \phi(x_j) \quad (26)$$

Dado que el cálculo de $(\phi(x_i) \cdot \phi(x_j))$ es computacionalmente costoso debido a que h es mayor a n , se hace uso de las funciones kernel. Las funciones kernel obtienen el producto escalar en el espacio de características realizando el cálculo en el espacio de estrada con una complejidad considerablemente menor. Así, el método kernel evita la necesidad de conocer explícitamente la función ϕ [279] haciendo que en los casos no lineales sean equivalentes a aplicar una función a los datos entrada y aplicar SVM a los datos resultantes que pertenecen a un nuevo espacio [278].

El HSO de una SVM no lineal está dado por la sustitución del producto escalar en el espacio de estrada $(\vec{x}_i \cdot \vec{x}_j)$ por el kernel haciendo al Lagrangiano definirse como [271]:

$$L = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(\vec{x}_i, \vec{x}_j)$$

$$0 \leq \alpha_i \leq C \quad (27)$$

$$\sum_i^n \alpha_i y_i = 0$$

2.13 Técnicas de procesamiento de señales

2.13.1 Transformada de Fourier

La transformada de Fourier (FT) es una herramienta poderosa utilizada en el análisis de señales y considerada crucial en muchas aplicaciones de computación científica y la ciencia de datos [280]. 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 [280], [281], que al sumarse tendrían la forma de exacta de la función original [282].

Existen funciones cuya representación es exacta por medio de una suma finita de N senoides. En cambio, existen otras funciones con las que solo es posible realizar una suma parcial para obtener una aproximación adecuada cuyo error tiende a cero al considerar más términos o frecuencias [282]. 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 en la ecuación 28 [282].

$$f(t) \cong a_0 + \sum_{n=1}^N a_n \cos(n\omega_0 t) + \sum_{n=1}^N b_n \sin(n\omega_0 t) \quad (28)$$

Donde a_0 , a_1 y b_n son los coeficientes trigonométricos de Fourier, mientras que ω_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 se incremente [283]. Para ello, se cuenta con la transformada rápida de Fourier (FFT) o transformada discreta de Fourier (DFT). Tanto la FFT como la DFT son utilizadas en la literatura de forma indiferente, sin embargo, el FFT es un algoritmo que calcula la transformada discreta de Fourier [280].

La transformada discreta de Fourier realiza el análisis espectral de una señal, trasladándose del espacio de tiempo discreto al espacio de frecuencias (ver Figura 37) donde es posible obtener información de las componentes frecuenciales predominantes de una señal [284]. La DFT transforma la señal analizada del dominio del tiempo de N puntos en dos señales nuevas, una parte real y una imaginaria, en el dominio de la frecuencia de N puntos. En el dominio de la frecuencia la señal se descompone en correspondiente sinusoidal de diferentes frecuencias [285].

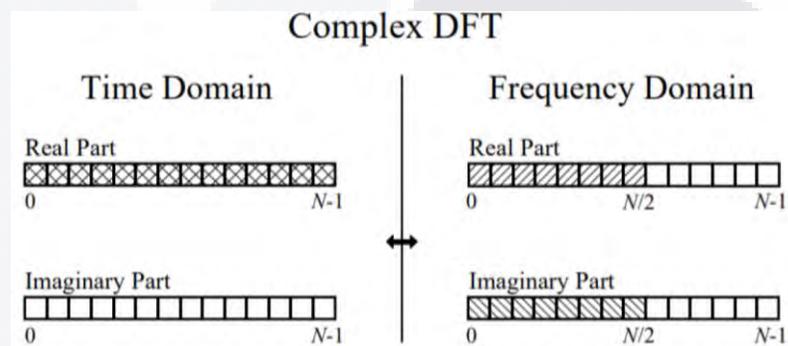


Figura 37. Transformada discreta de Fourier. Obtenida de [286].

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 (29) [285]:

$$y[k] = \sum_{n=0}^{N-1} e^{-2\pi j \frac{kn}{N}} x[n] \quad \text{con } k = 0, 1, \dots, N - 1 \quad (29)$$

La transformada de Fourier presenta características importantes, entre ellas, la linealidad, lo que significa que posee la propiedad distributiva respecto de la suma. Además, 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 $\frac{N}{2} + 1$ 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 [287].

2.14 Métodos de toma de decisiones multicriterio

El mundo actual está en constante cambio, donde existen entornos dinámicos llenos de incertidumbres, complejidades, ambigüedades y crecientes expectativas de usuarios y clientes, lo que representa un reto de eficiencia y agilidad por parte de la industria [288], [289]. Si bien el contexto es dinámico, es importante señalar que este hecho ha favorecido la integración de la tecnología y su digitalización por medio de sistemas inteligentes [4]–[6]. Este nuevo universo de aplicaciones y tecnologías ofrecen un nuevo soporte en la vida cotidiana de los usuarios con nuevas infraestructuras para el acceso a la cultura, el ocio, la educación, el comercio y servicios de salud, por destacar algunos [4], [8].

De acuerdo con lo mencionado a lo largo de este trabajo de tesis, la tecnología ha evolucionado lo suficiente para tener la capacidad de procesar grandes cantidades de información [290]. Esto gracias a la introducción de enfoques como el internet de las cosas, redes de sensores inalámbricas, big data, computación en la nube, internet móvil, entre otros [291]. A su vez, esto implica que procesos de control y operación se vuelvan más complejos [292], [293]. Lo que resulta en que los procesos de toma de decisiones, que comparan diferentes alternativas y consideran múltiples criterios, se vuelvan una tarea complicada. Especialmente lidiando con ambientes multicriterio y multi experto [294], y la necesidad de decisiones en tiempo real [295].

Los métodos para la toma de decisiones multicriterio (MCDM, Multi-criteria decision-making methods) se han desarrollado como parte de la investigación de operaciones y representan un enfoque que permite la evaluación y toma de decisiones en problemas complejos donde se involucran factores tanto cualitativos como cuantitativos [296]. Este tipo de problemas poseen criterios contrapuestos, alta incertidumbre y diferentes objetivos a considerar simultáneamente, además de diferentes tipo de datos y múltiples perspectivas e intereses [297], [298]. Como definición, un MCDM *“es un procedimiento que combina el desempeño de diferentes*

alternativas de decisión a través de varios criterios contradictorios, cualitativos y/o cuantitativos, dando como resultado una solución conciliada” [299].

En la literatura, es posible encontrar una serie de técnicas y métodos formales que denotan un proceso específico para llegar a la mejor alternativa de decisión [297]. En este sentido, MCDM es un concepto genérico para aquellos métodos existentes que ayudan en la toma de decisiones de acuerdo con preferencias específicas [296]. Este tipo de técnicas tiene un amplio espectro de aplicaciones en problemas de la vida cotidiana y en actividades industriales donde se consideran diferentes alternativas con criterios de evaluación que pueden conflictuar unos con otros [299]. Algunas aplicaciones se encuentran en la ingeniería, evaluación de riesgos, diseño de manufactura, selección de materiales, modelado computacional, etc. [298], [300]. Es así que, los métodos MCDM son aplicados en problemas de la vida real y en actividades industriales donde se requiere considerar diferentes alternativas donde los criterios de evaluación pueden entrar en conflicto unos con otros [299].

Un problema común de toma de decisiones multicriterio se distingue por ordenar un conjunto de alternativas bajo un conjunto de características específicas, normalmente basadas en una matriz de decisión con puntuaciones para cada alternativa [301]. De manera general, un método para la toma de decisiones multicriterio sigue los siguientes pasos:

1. *“Determinar los criterios y alternativas relevantes”.*
2. *“Asignar medidas numéricas a la importancia relativa de los criterios y el impacto de las alternativas en estos criterios”.*
3. *“Procesar los valores numéricos para determinar el ranking de cada alternativa”.* [302]

En la Tabla 3 se muestra algunos de los métodos de toma de decisiones multicriterio más utilizados. Cada uno de ellos representa una perspectiva específica para abordar un problema, y por consiguiente, poseen sus propios requerimientos[299], [303].

Tabla 3. Métodos de toma de decisiones multicriterio [297], [299], [302]

Enfoque	Método	Autor(es)
Métodos basados en valores	AHP (Proceso jerárquico analítico)	Saaty [1980]
	WSM (Modelo de suma ponderada)	Fishburn [1967]
	WPM (Modelo de producto ponderado)	Bridgman [1922], Miller and Starr [1969]
	ELECTRE (Eliminación y elecciones que reflejan la realidad; traducción del francés: elimination et choix traduisant la réalité)	Benayoun, et al. [1966]
	TOPSIS (Técnica para el ordenado de preferencias por similitud a la solución ideal)	Yoon and Hwang [1980]

En la literatura se encuentra un gran número de aplicaciones de toma de decisiones multicriterio en diferentes contextos. Por ejemplo, Damidavicius et al. en [304] exponen un estudio acerca de la planeación de un sistema de transporte sustentable en que hicieron uso de métodos MCDM para la evaluación de diferentes sistemas de transporte urbano y su potencial en términos de movilidad sustentable en ciudades de Lituania. Esto con el objetivo de promover inversiones en transporte no motorizado e infraestructura pública alineada con la importancia del cuidado ambiental.

Por su parte, Siksnyte et al. [305] presentan un panorama general del uso de métodos MCDM en la literatura. Todo ello, orientando a la solución de problemas de sustentabilidad en el sector energético. Los autores ponen en evidencia el incremento de estudios basados en aplicaciones de métodos MCDM desde el año 1990 hasta 2017, tal como se muestra en la Figura 38. Todo ello gracias a su universalidad y amplia selección de problemas específicos en los que se pueden aplicar este tipo de metodologías, lo que resulta en una ganancia creciente de popularidad.

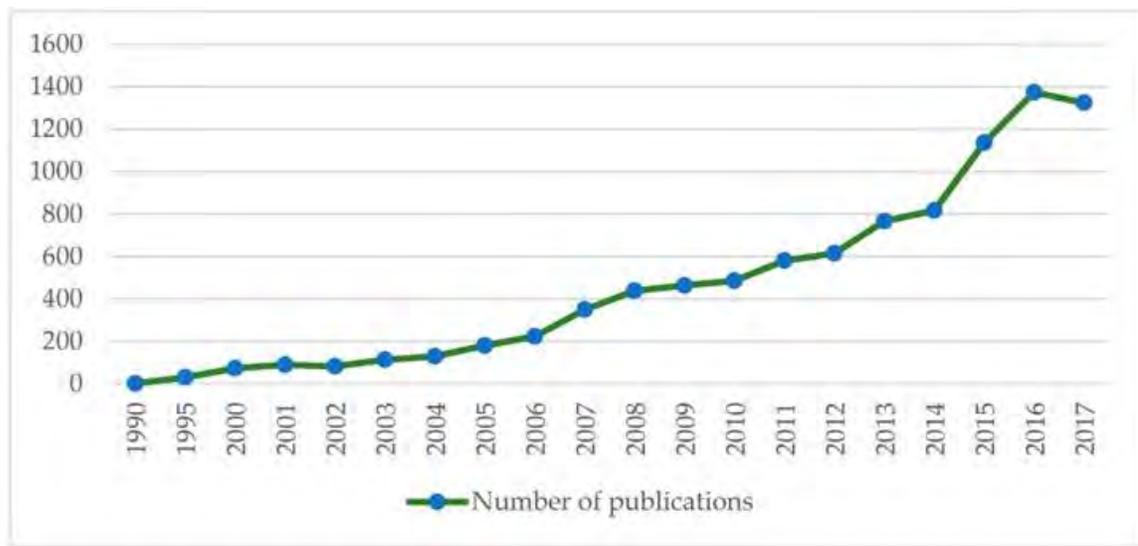


Figura 38. Publicaciones orientadas a métodos MCDM, 1990-2017. Extraído de [305].

Por otro lado, Esra Aytaç Adalı and Ayşegül Tuş [306], reportan un estudio relativo a la selección de la ubicación de un hospital con la aplicación de métodos MCDM basados en distancias como hace TOPSIS, descrito en la sección 2.14.1; EDAS, Evaluation based on Distance from Average Solution; y CODAS, Combinative Distance-Based Assessment). Su principal motivación radica en el rápido crecimiento de la población y en la vital importancia que tiene el acceso a diferentes servicios de salud. Así, la ubicación de un hospital conlleva una decisión estratégica importante, pues se busca que éste sea accesible a la mayor parte de la población posible. Los criterios que los autores tomaron en cuenta fueron el costo, el medio ambiente y la demografía de la ciudad. Al final, el estudio concluyó con la obtención del mismo ranking en los tres métodos MDCM y, por lo tanto, los autores concluyen en que estos métodos orientados al cálculo de distancias pueden usarse en sustitución uno del otro.

Para este trabajo de tesis se utilizó el método TOPSIS, el cual es descrito en la siguiente subsección.

2.14.1 TOPSIS

El método TOPSIS (Technique for Order Preference by Similarity to Ideal Solution) es una estrategia sólida para la toma de decisiones multicriterio en el que se determina la mejor solución de un conjunto de alternativas descritas por una serie de atributos [307], [308]. El método TOPSIS posee ventajas respecto a otros métodos para la toma de decisiones [308]:

1. Soporte para muchas alternativas y atributos.
2. Pocos requerimientos de entrada.
3. Naturaleza lógica y programable.
4. Consistencia comparativa en el ranqueo de las alternativas.

El método de TOPSIS se basa en los conceptos de la solución ideal y la solución no-ideal [297]. Es decir, este método busca la mejor solución la cual, minimiza la distancia geométrica desde la solución ideal positiva (PIS), es decir, la mejor solución teórica. Esta solución, a su vez, maximiza la distancia desde la solución negativa ideal (NIS), esto es, la peor solución teórica [297], [303].

$$A = \begin{matrix} a_1 \\ a_2 \\ \vdots \\ a_m \end{matrix} \begin{bmatrix} x_{1,1} & x_{1,2} & \dots & x_{1,n} \\ x_{2,1} & x_{2,2} & \dots & x_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m,1} & x_{m,2} & \dots & x_{m,n} \end{bmatrix} \quad (30)$$

$$C = c_1 \quad c_2 \quad \dots \quad c_n \quad (31)$$

$$W = w_1 \quad w_2 \quad \dots \quad w_n \quad (32)$$

Para encontrar la mejor solución en un problema de decisión dado, el método TOPSIS se basa en los siguientes pasos:

1. **Construcción de la matriz de decisión.** La matriz de decisión (Ecuación 30) se compone de m alternativas $A = \{a_1, a_2, \dots, a_m\}$ evaluados en términos de n criterios C (ver Ecuación 31). En la matriz de decisión, cada valor $x_{i,j}$ representa la medida de desempeño para la alternativa a_i . Por su parte, el

vector W (ver Ecuación 32) es un vector de pesos asociados al conjunto de criterios C (ver Ecuación 31) [297], [301], [302].

2. **Normalización.** Dado que los criterios pueden no pertenecer a un mismo dominio, el segundo paso consiste en una normalización de estos valores. Cada valor que compone una matriz de decisión normalizada se obtiene a partir de la ecuación 33 [301], [302], [308]:

$$r_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^m x_{ij}^2}} \quad j = 1, 2, \dots, n; i = 1, 2, \dots, m \quad (33)$$

Donde cada elemento r_{ij} pertenece la matriz de decisión normalizada (Ecuación 34), y el valor x_{ij} es un elemento de la matriz de decisión original (Ecuación 30).

$$R = \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1n} \\ r_{21} & r_{22} & \dots & r_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ r_{m1} & r_{m2} & \dots & r_{nm} \end{bmatrix} \quad (34)$$

3. **Construcción de la matriz de decisión normalizada ponderada.** La matriz de decisión normalizada ponderada V (ecuación 35) se obtiene a partir de la matriz de decisión normalizada R de la ecuación 34 y el conjunto de pesos W de la ecuación 32, donde $\sum w_i = 1$ [301], [302], [307]. Cada valor w_i es asignado por el tomador de decisiones y está asociando con el *criterio* c_i .

$$V = \begin{bmatrix} v_{11} & v_{12} & \dots & v_{1n} \\ v_{21} & v_{22} & \dots & v_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ v_{m1} & v_{m2} & \dots & v_{nm} \end{bmatrix} \quad (35)$$

Cada valor v_i esta dado por la ecuación 36, a continuación [301]–[303], [307]–[309]:

$$v_{ij} = r_{ij} * w_j \quad (36)$$

4. **Obtención de la solución ideal (A^+) y la solución no-ideal (A^-)**[307], [308]. Ambas soluciones son ficticias [302]. A^+ (Ecuación 37) es la solución ideal, es decir, posee el máximo valor respecto de otras alternativas según sus criterios de beneficio. Por su parte, A^- (Ecuación 38) es la solución no-ideal con el menor valor para los criterios de costo, es decir, es la solución menos deseada [301], [302].

$$A^+ = \{v_1^+, \dots, v_n^+\} = \{(max_i v_{ij}, j \in J)(min_i v_{ij}, j \in J')\}; i = 1, \dots, m \quad (37)$$

$$A^- = \{v_1^-, \dots, v_n^-\} = \{(min_i v_{ij}, j \in J)(max_i v_{ij}, j \in J')\}; i = 1, \dots, m \quad (38)$$

El valor $J = \{j = 1, 2, \dots, n\}$ se asocia con los criterios de beneficio, mientras que el valor $J' = \{j = 1, 2, \dots, n\}$ se asocia a los criterios de costo [301], [302], [309].

5. **Obtención de distancias.** En este paso se calcula la distancia euclidiana de la i – ésima alternativa a la solución ideal (ver Ecuación 39) [297], [299], [302]:

$$s_i^+ = \sqrt{\sum_{j=1}^m (v_{ij} - v_j^+)^2} \quad (39)$$

Y, además, se calcula la distancia euclidiana de la i – ésima alternativa a la solución no-ideal (ver Ecuación 40) [297], [299], [302]:

$$s_i^- = \sqrt{\sum_{j=1}^m (v_{ij} - v_j^-)^2} \quad (40)$$

6. **Obtención de la cercanía relativa.** La Ecuación 41 permite conocer la cercanía relativa desde cada alternativa a_i a la solución ideal [301], [302]. Así, cuando el valor R_i tiende a 1, significa que la alternativa a_i más cercana está a la solución ideal [301], [307], [309].

$$R_i = \frac{s_i^-}{s_i^+ + s_i^-}, i = 1, \dots, m \quad (41)$$

7. **Obtención de jerarquías.** El paso final del método TOPSIS, para la toma de decisiones multicriterio, consiste en establecer la jerarquía de preferencias ordenando las preferencias a_i comenzando con aquella con el *valor* R_i más cercano a la solución ideal [297], [309]. Es decir, *“la mejor alternativa posee la distancia más corta a la solución ideal”* [302].

Capítulo III

Propuesta metodológica para la obtención y manipulación de señales EEG-MI

La Figura 39 expone la propuesta metodológica seguida para la elaboración de este reporte de tesis y, por consiguiente, la creación del modelo MHH-FSS-RNA, especializado en la clasificación de intención de movimiento a través de señales EEG. De manera general, la metodología propuesta comprende desde la selección del dispositivo de captura de señales electroencefalográficas con intención de movimiento (EEG-MI), hasta la creación de un modelo de clasificación para la distinción de intenciones de movimiento (abrir/cerrar la mano).

Como se muestra en la Figura 39, la metodología se conformó por fases para el logro de los objetivos expuestos en el apartado 1.4. La Fase 1 consistió en el estudio de distintos dispositivos comerciales de captura de señales EEG. Este tipo de dispositivos permiten la medición no invasiva de los campos eléctricos del cerebro generados por la actividad neuronal (para más información, consultar la sección 2.4). Entre los dispositivos analizados se encuentra el Emotiv EPOC+, NeuroSky, Muse, entre otros. Cada uno con distintas especificaciones, lo que se traduce en distintas ventajas y desventajas entre los distintos dispositivos.

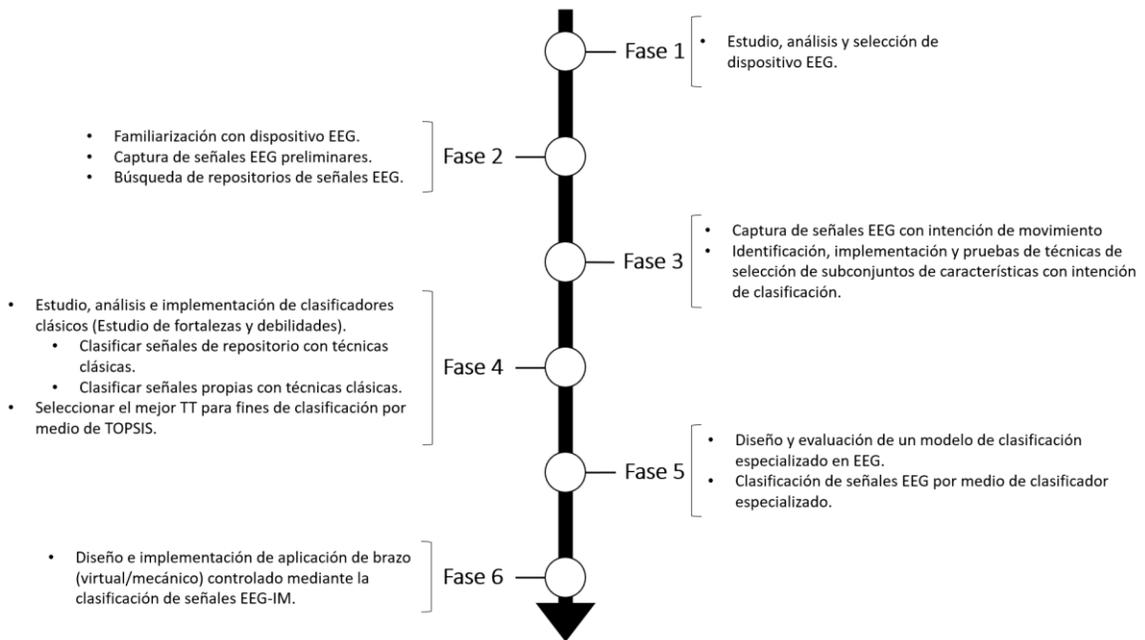


Figura 39. Metodología.

Como se recordará, el objetivo del uso de un dispositivo de captura de señales EEG es la detección de intención de movimiento (MI), específicamente en su forma cinestésica. Es decir, cada uno de los sujetos de prueba generó la representación de lo movimiento (intención de movimiento) en primera persona evocando los sentimientos y sensaciones producidas al realizar el movimiento real (ver sección 2.3). Para este trabajo de tesis se centró en la intención del movimiento de abrir y cerrar la mano derecha.

Una vez seleccionado el dispositivo de captura, se procedió con la puesta en marcha de la Fase 2. De acuerdo con la Figura 39, esta fase consistió en la familiarización el dispositivo seleccionado, el Emotiv EPOC+. La Fase 2 permitió conocer sus características a detalle, su colocación en los sujetos de prueba, la captura de las señales y el software requerido para ello, así como el diseño de protocolos de captura en beneficio del correcto registro de señales EEG-MI. La Fase 2 incluyó, además, la búsqueda de repositorios de señales EEG capturadas por el dispositivo de Emotiv EPOC+ con la finalidad de utilizarlos como prueba para la Fase 3 de la metodología.

La Fase 3 consistió la captura de señales EEG-MI con el apoyo de los protocolos de captura definidos en la anterior y el dispositivo Emotiv EPOC+ seleccionado en la Fase 1. Esto, con el objetivo de construir un repositorio propio. Se incluye, además, la tarea de preprocesamiento de las señales EEG-MI que comprende un análisis de correlaciones de los datos para conocer la relación existente entre las variables que describen las señales EEG-MI.

Como segunda tarea dentro de la Fase 3, se aplicó un análisis de selección de subconjuntos de características (SSC) (sección 2.7) por medio de la teoría de testores que, a su vez, forma parte del enfoque lógico-combinatorio del reconocimiento de patrones (sección 2.6). El objetivo de la aplicación de la teoría de testores es trabajar el modelo de clasificación con aquellas características que incidan de forma determinante en la intención de movimiento de abrir/cerrar la mano derecha. En esta sección de la Fase 3 se realizó la inclusión el operador (OA) de alteración en el algoritmo genético y el algoritmo de estimación de la distribución para la búsqueda de testores típicos en problemas médicos. Esto con el objetivo de realizar una búsqueda metaheurística para evitar el cálculo exhaustivo que, como se recordará, es un problema de crecimiento exponencial respecto del número de características a analizar.

Como última experimentación se extrae el conjunto de testores típicos correspondientes al repositorio de señales EEG-MI obtenido al inicio de la Fase 3. Con base al conjunto obtenido, se realizó el cálculo del peso informacional como una medida de significancia que indica cuán importante es una característica en la diferenciación de clases. Esto es, entre mayor sea el valor de peso informacional, la característica se vuelve crucial y, por tanto, no será posible descartarla del conjunto de características que describe un objeto o fenómeno.

Por su parte, la fase 4 continúa con el análisis, estudio e implementación de distintos algoritmos clásicos de aprendizaje automático. Dichos algoritmos permiten la clasificación de objetos a partir del análisis de los valores en sus características descriptivas (consultar apartados 2.9, 2.11 y 2.12). En esta fase algoritmos, como

las máquinas de soporte vectorial (sección 2.12.3) y las redes neuronales artificiales (sección 2.12.2), fueron comparadas con la intención de identificar las ventajas y desventajas que poseen. Una vez conocidos los clasificadores y el conjunto de testores típicos, la Fase 4 culmina con un análisis para la toma de decisiones multicriterio por medio del método TOSIS (sección 2.14.1). Este tipo de métodos permiten el análisis y evaluación en problemas de toma de decisión en los que se involucran factores cualitativos y cuantitativos, así como la consideración de criterios contrapuestos. Específicamente, el uso de TOPSIS permitió la selección del mejor testor típico con pocos requerimientos de entrada, su facilidad de implementación, así como el ranqueo de cada testor típico.

La Fase 5 se dedica a la integración de las fases previas para la construcción del mecanismo híbrido de clasificación MHH-FSS-RNA, especializado en la clasificación de señales EEG-MI. Es decir, un modelo híbrido de clasificación que conforma de los siguientes elementos:

1. El diseño de un protocolo de captura de señales EEG-MI.
2. Un método para el preprocesamiento de las señales EEG-MI.
3. La integración de la teoría de testores para la reducción de la dimensionalidad.
4. La integración de TOPSIS (mejor subconjunto de características o testor típico).
5. La implementación de un algoritmo de aprendizaje automático clásico para la clasificación de señales EEG-MI.

El mecanismo MHH-FSS-RNA fue sometido a la afinación empírica de parámetros. Proceso en el cual, se entrenó la red neuronal artificial interna con señales de intención de movimiento de un sujeto de prueba. Esto con el objetivo de encontrar el modelo RNA interno equilibrado, es decir, un modelo con el menor requerimiento de recursos computacionales, pero con el mejor desempeño posible.

Finalmente, la Fase 6 se enfoca exclusivamente en probar el modelo a través del control de un dispositivo externo, en este caso, un brazo mecánico. En esta fase,

se pone a prueba el mecanismo MHH-FSS-RNA con un nuevo repositorio de señales obtenida del mismo sujeto de prueba para el cual, fue entrenado y validado.

Cabe recalcar, que ambos repositorios, el de entrenamiento y validación y el de pruebas fueron obtenidos en la misma sesión de muestreo para asegurar que ambos repositorios compartieran exactamente las mismas condiciones ambientales de muestreo. Además, como se mencionó en el apartado 2.4, se seleccionó un solo sujeto de prueba debido a la naturaleza altamente variable de las señales EEG entre sujetos de prueba.

Así, cada registro en el repositorio es clasificado de forma supervisada por el mecanismo MHH-FSS-RNA y, una vez, toma la decisión, se envía la señal correspondiente al brazo mecánico el cual, realiza el movimiento de intención resultante de abrir o cerrar la mano.

A continuación, en el capítulo IV se expone cada uno de los resultados obtenidos con la aplicación de las fases que componen la metodología expuesta en la Figura 39.

Capítulo IV

Implementación y resultados de la propuesta metodológica

4.1 Fase 1

Retomando la propuesta metodológica presentada en el capítulo anterior (ver Figura 39), la Fase 1 consistió en el análisis de diferentes dispositivos de electroencefalograma disponibles de forma comercial. Cada uno de ellos presentó ventajas y desventajas, uno respecto al otro en cuanto al número de electrodos disponibles, su compatibilidad con lenguajes de programación, su facilidad y practicidad para la captura de las señales crudas, así como el acceso a los registros para la aplicación de técnicas de análisis de datos, preprocesamiento y aprendizaje automático.

Tabla 4. Comparación de dispositivos EEG comerciales.

Dispositivo	Características	
Neuphony Headband https://neuphony.com/	Canales	8 sensores EEG en seco
	Conectividad	Bluetooth 4.2, USB C
	Tasa de muestreo	No especificado
	Espectros	EEG y acelerómetro
	Batería	Recargable, +8hrs de uso
	Plataformas	Android y iOS Desktop App
	Otras características	Análisis de emociones, análisis de concentración, análisis de desempeño en tiempo real, análisis durante meditación

Muse 2 https://choosemuse.com/	Canales	4 canales + 2 sensores de referencia
	Conectividad	Bluetooth 4.2, micro USB
	Tasa de muestreo	No especificado
	Espectros	EEG, oximetría de pulso, acelerómetro, frecuencia cardíaca, sensor de respiración
	Batería	Recargable, 5hrs de uso
	Plataformas	iOS 11, Android 5 o superior (No Huawei)
	Otras características	Múltiples usuarios, orientado a meditación, señales crudas para investigación por medio de Muse Direct (solo iOS).
Emotiv EPOC+ https://www.emotiv.com/	Canales	14 canales + 2 sensores de referencia (requieren solución salina, NO geles)
	Conectividad	Bluetooth, micro USB
	Tasa de muestreo	128 a 256 muestras/segundo
	Espectros	EEG, acelerómetro, magnetómetro.
	Batería	12hrs
	Plataformas	Windows 7, 8, 10, Mac OS X, iOS 9+, Android 4.3+
	Otras características	Señales crudas bajo licencia, medidas de desempeño y detección de expresiones faciales.
Mindwave mobile 2 https://store.neurosky.com/	Canales	2 canales + 1 sensor de referencia
	Conectividad	Bluetooth
	Tasa de muestreo	512 registros/segundo
	Espectros	EEG
	Batería	Batería AAA, 8hrs
	Plataformas	Windows XP, 7, 8, 10, Mac OSX 10.8+, iOS 8+, Android 2.3+
	Otras características	Detección de atención, meditación, señales crudas disponibles (NeuroView), compatible con Matlab 7.0+

La Tabla 4 muestre los diferentes dispositivos EEG que se analizaron. Al final del estudio se eligió trabajar con el modelo EPOC+ de Emotiv de la Figura 40. El dispositivo Emotiv EPOC+ permite la captura y amplificación de las ondas cerebrales. La principal ventaja de este dispositivo sobre el resto es su orientación a la investigación, específicamente en la construcción de aplicaciones cerebro-computadora, investigación en neurociencia o el desarrollo de aplicaciones EEG [310].



Figura 40. Emotiv EPOC+ (Figura tomada de la web oficial [310]).

Otra de las ventajas es, como se observa en la Tabla 4, es la disponibilidad de catorce receptores (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4) distribuidos de acuerdo con el sistema internacional 10-20. Este sistema consiste en un estándar internacional que describe la correcta localización de electrodos en el cuero cabelludo [286], independientemente del tamaño de la cabeza [311].

Como se puede observar en la Tabla 5, cada zona es identificada por una letra y un número que indica el lóbulo y el hemisferio (hemisferio izquierdo con números impares y hemisferio derecho con número pares) [286], tal como se expone en la Figura 41.

Tabla 5. Nomenclatura del sistema internacional 10-20. Obtenida del trabajo de [286].

Electrodo	Lóbulo
F	Frontal
T	Temporal
C	Central*
P	Parietal
O	Occipital
*Lóbulo referencial, solo para identificación	

El sistema 10-20 recibe su nombre debido a que utiliza el 10% o el 20% de distancias especificadas anatómicamente para colocar los electrodos [311].

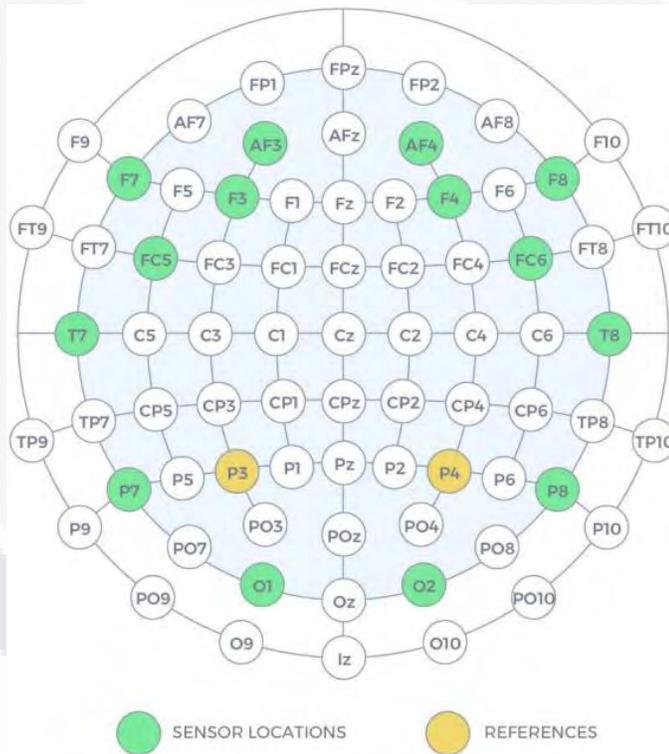


Figura 41. Sistema 10-20 y Distribución de electrodos del Emotiv EPOC+ [310], [312].

4.2 Fase 2

4.2.1 Emotiv EPOC+

Tal como lo indica en la metodología de la sección 3, la Fase 2 comprende la familiarización con el funcionamiento del dispositivo EEG seleccionado en la Fase 1 descrita en la sección anterior. En este caso, el dispositivo es el Emotiv EPOC+ cuyas características son publicadas por [286] y disponibles, además en la web oficial del proveedor en [310] (ver Figura 42).

Características del dispositivo Emotiv EPOC +		
Sensores EEG	Canales	14 de adquisición: AF3,F7, F3, FC5, T7, P7, O1,O2, P8, T8, FC6, F4, F8, AF4 2 de Referencia: CMS/DRL ubicados en las posiciones P3 y P4.
	Material	Almodillas de fieltro remojadas en solución salina (NaCl 9%).
	Conectividad	Inalámbrica: - Bluetooth (Baja Energía) - Receptor Dongle USB (Banda 2.4Ghz) Alámbrica: Mediante USB (Solo para configurar el casco).
Señales EEG	Muestreo	- Muestreo secuencial: Un solo ADC. - Tasa de Muestreo: 2048 disminuido a 128 o 256 muestras/s
	Resolución digital	- 14 bits con $LSB=0.51\mu V$ - 16 bits (Por configuración)
	Ancho de Banda	0.16-43Hz con filtros digitales notch en 50Hz y 60Hz.
	Filtrado	Filtro sinc de 5th orden
	Rango de voltaje	8400 μV_{pp}
Sensores de Movimiento	Modelo	ICM-20948
	Acelerómetro	3 Ejes +/- 4g
	Magnetómetro	3 Ejes +/- 4900nT
	Tasa de Muestreo	0 /32 /64Hz (Configurado por usuario)
Plataformas Soportadas		- Windows 7,8,10 - Mac OS X - iOS: 9 o superior. - Android 4.43+
Batería	Material	Polímero de litio de 640mAh
	Duración	- 12 hrs. usando receptor USB - 6 hrs. usando Bluetooth
Detecciones posibles	Señal cruda *	Solamente si se dispone de una licencia.
	Medidas de desempeño	- Emoción, Acción, Relajación, Interés, Estrés, Concentración.
	Expresiones Faciales	- Parpadeo, Guiño Izq.\Der., Sorpresa, Ceño fruncido, Sonreír.

Figura 42. Especificaciones detalladas del dispositivo Emotiv EPOC+ [286], [310].

Como ya se mencionó, el dispositivo EEG de Emotiv, el Emotiv EPOC+, posee 14 electrodos distribuidos en el cuero cabelludo, registrando las señales en μV . Lo que permite una mejor observación de la actividad cerebral de todas las zonas de la corteza cerebral. Recordando que las señales registradas comprenden la suma de toda la actividad cerebral, es decir, comprende la acumulación de información desde zonas subcorticales hasta las corticales, incluyendo artefactos fisiológicos como los movimientos oculares, musculares y el latido del corazón, por mencionar algunos, hasta factores técnicos como las líneas de alimentación y la desconexión de electrodos [126].

Para la realización de capturas de señales EEG-MI se hizo uso de la aplicación de código abierto CyKit de CymatiCorp [313] (ver Figura 43.A) y de la aplicación OpenVibe (ver Figura 43.B), un software para el diseño, prueba y uso de interfaces cerebro-computadora, además de permitir la adquisición, visualización, filtrado y procesamiento de señales EEG en tiempo real [314].

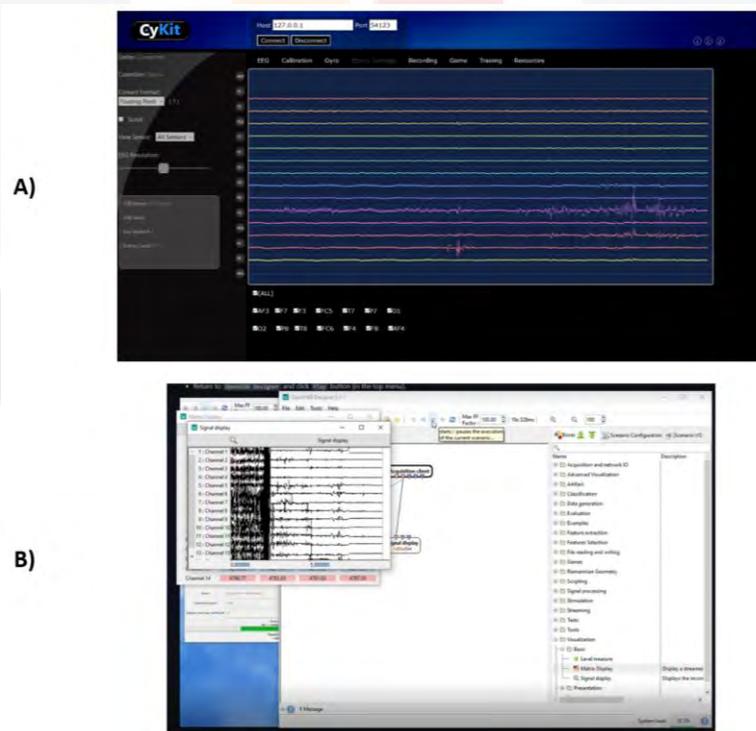


Figura 43. (A) Interfaz de Cykit [313] y (B) Funcionamiento de OpenVibe (imagen propia).

Ambas aplicaciones permitieron la creación de repositorios de datos y su almacenamiento en archivos CSV para su procesamiento en las fases subsecuentes.

4.2.2 Búsqueda de repositorios con señales EEG

Al momento de la realización de esta sección de la Fase 2 de la metodología solo fue posible encontrar un repositorio libre con registros de señales EEG obtenidas, precisamente, con el dispositivo Emotiv EPOC+ seleccionado en la Fase 1. Cabe aclarar que el repositorio no contiene la detección de intenciones de movimiento. El repositorio encontrado consiste en la detección del estado del ojo (abierto o cerrado). Se compone de 14,980 registros de valores EEG descritos por catorce características correspondientes a los catorce electrodos del EPOC+. La descripción general del repositorio se muestra en la Tabla 6.

El repositorio se encuentra disponible en los repositorios de aprendizaje automático de la Universidad de California: UC Irvine Machine Learning Repository [315].

Tabla 6. Descripción del repositorio de detección del estado del ojo con señales EEG.

Nombre del Repositorio:	EEG Eye State Data Set
Ubicación:	https://archive.ics.uci.edu/ml/datasets/EEG+Eye+State
Total de Instancias:	14,980
Numero de atributos:	15 (14 características con valores EEG y 1 de clase: valor 1 para ojo cerrado y valor 0 para ojo abierto)
Origen:	Baden-Wuerttemberg Cooperative State University (DHBW), Stuttgart, Germany
Fecha:	10 de junio de 2013

4.2.3 Desarrollo de protocolo de captura de datos EEG

Para realizar la captura de señales EEG-IM se trabajó en la creación de un protocolo de captura que permitiera la réplica del proceso de captura con cada uno de los sujetos de prueba que apoyaron la realización de este proyecto de tesis.

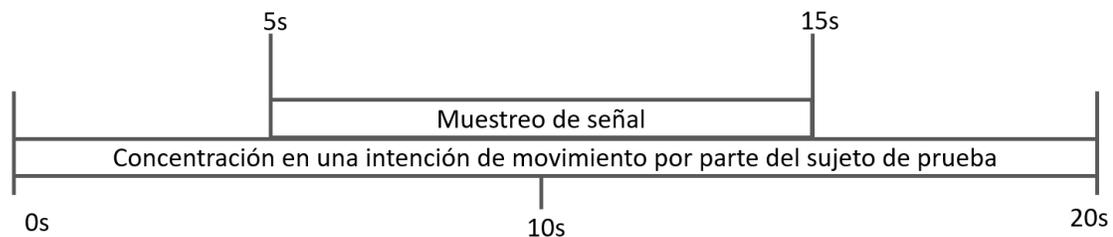


Figura 44. Protocolo de captura de señales EEG en su primera versión.

La Figura 44 muestra el primer prototipo de protocolo diseñado en el apoyo del primer sujeto de prueba y, a su vez, basado en el trabajo de Paredes et al en [286]. Como se puede observar, se trata de un pequeño proceso de veinte segundos en los cuales, el sujeto de prueba realiza el proceso consciente de una intención de movimiento específica, el movimiento de abrir o cerrar la mano en este caso. El proceso consta de cinco segundos de preparación en el que el sujeto de prueba inicia el proceso de evocación de la intención de movimiento especificada. A partir del segundo cinco hasta el segundo quince se realiza propiamente el proceso de captura con el dispositivo Emotiv EPOC+ y las aplicaciones Cykit y OpenVibe. Finalmente, el proceso concluye con el período de descanso que consta de los últimos cinco segundos especificados en la Figura 44. De esta manera, se pueden obtener alrededor de 1280 registros por cada aplicación del protocolo. Todo con base a la tasa de muestro de las especificaciones del dispositivo Emotiv EPOC+ de la Figura 42. Este primer diseño de protocolo se publicó en el trabajo titulado “Tratamiento de Señales Electroencefalográficas de Imaginación Motora con Fines de Clasificación” en la revista Research in Computer Sciences (ver Anexo A.5).

Sin embargo, el trabajo de tesis del alumno de la Maestría en Informática y Tecnologías Computacionales de la Universidad Autónoma de Aguascalientes

Carlos Martínez, “Aprendizaje Automático en la Interpretación de Señales Electroencefalográficas” [316], para el que se participó como asesor, permitió el desarrollo de un segundo modelo con un menor tiempo de captura. Esto, debido a que se consideró excesivo el tiempo de concentración requerido hacia los sujetos de prueba participantes. De manera que, se asegura la captura de la intención del movimiento bajo un buen nivel de concentración.

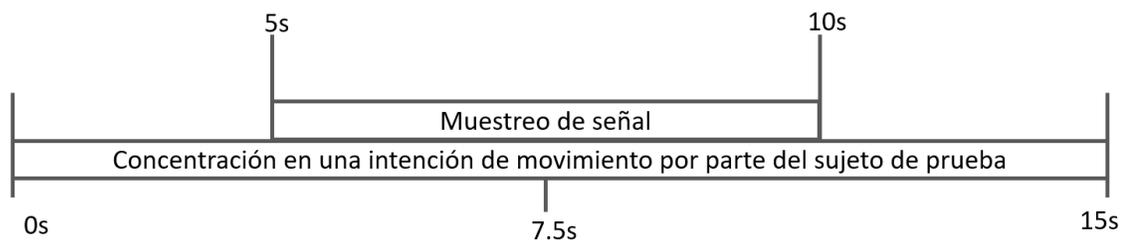


Figura 45. Segunda versión del protocolo de captura de señales EEG-MI.

De acuerdo con la Figura 45, este segundo modelo requiere de quince segundos de proceso. Durante este tiempo el sujeto de prueba se mantiene concentrado en la intención de movimiento solicitada. Al igual que en el modelo de la Figura 44, el modelo consta de cinco segundos de preparación (inicio de la concentración) para después iniciar propiamente la captura de la señal por otros cinco segundos. Finalmente, la captura es detenida cinco segundos antes de finalizar la prueba. Con el diseño de estos protocolos es posible un mejor control en la captura de la intención de movimiento del brazo.

Consideraciones ambientales

Tomando en cuenta que las señales eléctricas captadas por el dispositivo EEG se la suma de toda la actividad cerebral (ver secciones 2.2 y 2.4), es posible que la captura se vea afectada por el ambiente en el que se realiza. Por tanto, se tomaron en cuenta algunas consideraciones al respecto. Dichas consideraciones también fueron definidas en el trabajo del alumno Carlos Martínez en [316].

Las condiciones ambientales para la captura de señales EEG se enlistan a continuación:

- La habitación debe estar aislada de distracciones auditivas y visuales.
- Procurar la presencia de, únicamente, el sujeto de prueba y el experto de toma de muestras.
- Procurar una temperatura entre 18°C y 24°C.
- El experto solo debe limitarse a realizar indicaciones durante el proceso de captura.
- El sujeto de prueba debe permanecer en una sola posición, por lo que se recomienda asegurar una posición cómoda antes de iniciar con la aplicación del protocolo.
- El sujeto de prueba debe presentarse con higiene corporal previa, evitando el uso de cremas, lacas o geles para cabello. Además de retirar objetos y accesorios como anillos, relojes y pulseras.

4.2.4 Captura de señales preliminares

Para la captura preliminar de señales EEG con la intención de abrir y cerrar la mano de derecha se contó con un sujeto de prueba, quien cumple con las características de la Tabla 7.

Tabla 7. Características de sujeto de prueba para señales preliminares

Edad:	25
Sexo:	Masculino
Estado de salud general:	Bueno
Presencia de lesiones cerebrales:	Negativo
Padecimientos de salud mental:	Negativo
Uso de medicamentos controlado:	Negativo

Como primer acercamiento a la captura de señales EEG-MI con intención de abrir y cerrar la mano derecha se expone en la Tabla 8.

Tabla 8. Descripción de repositorio preliminar de intención de movimiento

Repositorio de señales EEG-MI 1	
Registros de cerrar mano	717
Registros de abrir mano	566
Total de registros	1,283

4.3 Fase 3

4.3.1 Captura de señales EEG-MI

La Fase 4 se orienta a la construcción de un repositorio de señales EEG-MI con la intención de abrir/cerrar la mano derecha. Para ello, se contó con la participación de seis sujetos de prueba bajo el cumplimiento de las siguientes características:

- Sexo indistinto
- Edad mínima 18 años y máxima de 35.
- Descanso de 8hrs.
- Buen estado general de salud.
- Ausencia de problemas de salud mental (ansiedad, pánico, etc.)
- No estar bajo tratamiento de medicamentos controlados.
- Presentarse con higiene corporal previa, evitando cremas, laca o geles para cabello.

Además, la captura fue realizada siguiendo el protocolo diseñado en la sección 4.2.3 y expuesto en la Figura 44. La construcción de este repositorio se realizó en el apoyo del alumno de maestría Carlos Martínez Díaz.

Finalmente, el repositorio de señales EEG-MI de abrir/cerrar la mano derecha se describe a continuación en la Tabla 9.

Tabla 9. Repositorio de señales EEG-MI de abrir/cerrar mano derecha

Repositorio de señales EEG-MI 2	
Registros de cerrar mano	11,656
Registros de abrir mano	12,190
Total de registros	23,846
Número de características	14 (mediciones en μV)



4.3.2 Análisis de correlaciones

El siguiente resultado de la Fase 3, se realizó el cálculo de la desviación estándar para cada una de las catorce características que describen el repositorio de datos descrito en la Tabla 9 de la sección anterior.

Como primer resultado de esta parte de la Fase 3, se realizó el cálculo de la desviación estándar para cada una de las catorce características que describen el repositorio de la Tabla 9.

Como se puede observar en la Tabla 10, a pesar de que los catorce nodos/características/electrodos del Emotiv EPOC+ (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4) miden el mismo tipo de variable (μV), los valores de las desviaciones estándar muestran gran dispersión entre sí. Por lo tanto, se decidió que uno de los elementos del preprocesamiento debe ser la normalización de los datos.

Tabla 10. Desviaciones estándar. Publicado en anexo A.8.

Nodo	STD	Nodo	STD
AF3	42.6789182478843	O2	57.3289657
F7	53.7523558	P8	71.0371007909142
F3	80.187847	T8	45.6327024207423
FC5	82.04517812232	FC6	93.0843388893872
T7	27.2264746337066	F4	122.134084225115
P7	70.5757321082372	F8	75.6765945803192
O1	40.6529441779588	AF4	53.3759259517592

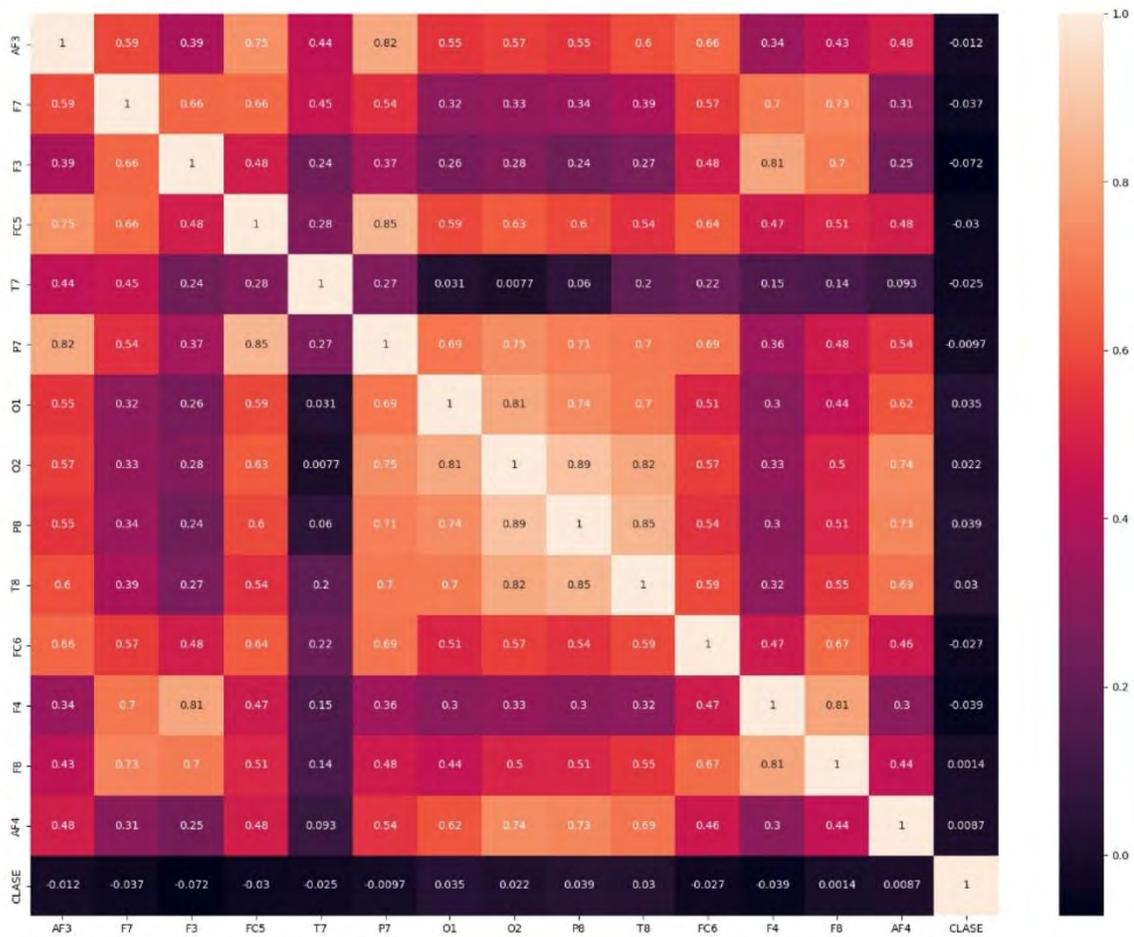


Figura 46. Análisis de correlaciones. Publicado en anexo A.8.

Para este análisis se calculó el coeficiente de correlación de Pearson el cual, permitió la elaboración de la gráfica de la Figura 46. El gráfico muestra que la totalidad de los coeficientes son superiores a 0 (tendencia al color blanco), lo que significa que existe una correlación positiva entre las catorce características involucradas. Es decir, cuando el valor de una incrementa, los valores del resto también lo harán. Sin embargo, se tienen valores muy cercanos a 0 (tendencia al color negro), lo que demuestra que no existe una relación lineal entre las características analizadas.

El análisis de correlaciones forma parte de la publicación “Feature Selection in Electroencephalographic Signals Using a Multicriteria Decision Analysis Method” descrito en el Anexo 4.8.

4.3.3 Análisis de selección de subconjuntos de características

El objetivo principal de este apartado es el cálculo de testores típicos (sección 2.7.1). Es decir, obtener subconjuntos de características que permitan una clasificación eficiente de señales utilizando una menor cantidad de recursos computacionales. En este caso se exponen los resultados de la realización de dos estudios de selección de subconjuntos de características por medio de la aplicación de la teoría de testores, como parte del enfoque lógico-combinatorio del reconocimiento de patrones (sección 2.6).

Búsqueda de testores típicos por medio de metaheurísticas evolutivas

Como se recordará, en la sección 2.7 se mencionó que la selección de subconjuntos de características es de gran importancia, como parte del reconocimiento de patrones, en aplicaciones de aprendizaje automático y la minería de datos, al permitir distinguir de manera eficiente aquellas características o rasgos irrelevantes y redundantes. Esto trae como consecuencia, la creación de modelos de análisis para clasificación, agrupamiento o regresión más sencillos y comprensibles, con mejor desempeño y con requerimientos computacionales menores [317]–[319].

Los resultados obtenidos en esta sección se encuentran publicados en la revista *Dyna New Technologies*, con el título Integración del operador de alteración a metaheurísticas evolutivas para la aplicación de la teoría de testores en patologías médicas [320] (Anexo A.1) y en la nota técnica Manipulación de metaheurísticas para la búsqueda de testores típicos [321] (Anexo A.3).

Tal como se menciona en la sección 2.7.1, la búsqueda exhaustiva del conjunto de testores típicos es un problema de tipo exponencial (2^n), donde n representa el número de características a analizar. Por esta razón, se realizó la hibridación de dos metaheurísticas evolutivas, el algoritmo genético (AG) y el algoritmo de estimación de la distribución (EDA). Todo por medio de la inclusión del operador de alteración

en ambas metaheurísticas, con el objetivo de enriquecer la búsqueda de los testores típicos inmersos en las soluciones generadas por los operadores clásicos. Así, su importancia radica en evitar que la búsqueda se vuelva una búsqueda aleatoria que pueda no encontrar el conjunto de testores típicos asociados al problema, así como de evitar su búsqueda exhaustiva.

Por su parte, el algoritmo genético es una técnica basada en poblaciones que inicia generando una de manera aleatoria para después, ser evaluada. El siguiente paso es cruzar soluciones para producir soluciones nuevas las cuales, se espera, sean mejores a las obtenidas por la generación anterior. Este proceso se repite hasta cumplir con las condiciones del problema [322]. El algoritmo genético es de amplia aplicación en la investigación en computación evolutiva debido a su robustez y fácil implementación [323].

Al igual que el algoritmo genético, el algoritmo de estimación de la distribución también se basa en poblaciones. La diferencia radica en la inserción de un modelo de probabilidad para producir nuevos descendientes, es decir, nuevas soluciones [324].

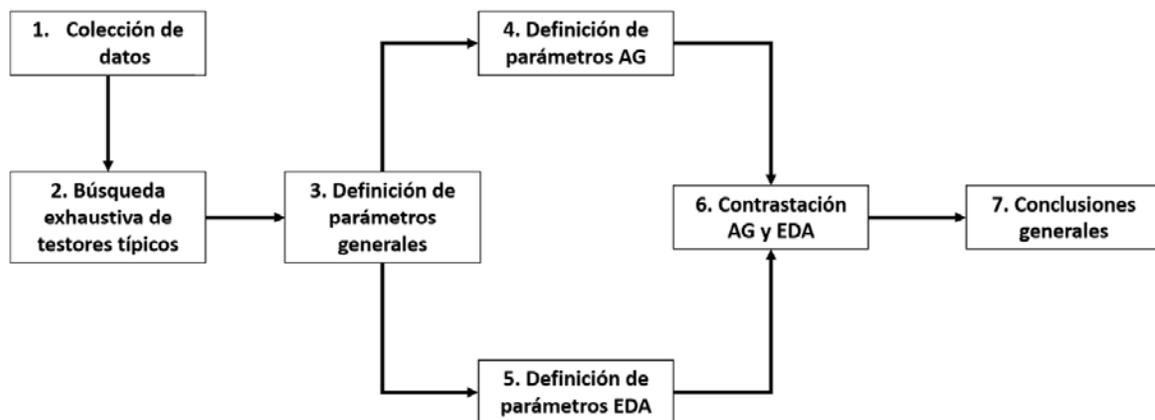


Figura 47. Metodología para la búsqueda de testores típicos por medio de la hibridación de metaheurísticas evolutivas. Publicado en [320].

La Figura 47 muestra la metodología seguida para la inclusión del operador de alteración en las metaheurísticas mencionadas (AG y EDA). El operador propuesto

permite la búsqueda de mejores soluciones a partir de las obtenidos por medio de los operadores comunes de ambas metaheurísticas. De esta manera se mejora la exploración del espacio de soluciones.

Para este estudio, se analizaron dos conjuntos de datos médicos que conforman el insumo principal de este estudio, de manera que se integran dos escenarios de experimentación. El primero de ellos, describe células de cáncer de mama clasificadas según su diagnóstico: benigna o maligna. Este conjunto constó de 569 instancias divididas en 365 células benignas y 212 malignas y fueron obtenidas del Machine Learning Repository de la UCI disponible en [325]. El segundo escenario consistió en una base de datos de uso personal facilitado por la Dra. Mariela Cardiel del Hospital N°1 del IMSS. Este conjunto de datos describe el estado de pacientes con hemofilia en el Estado de Aguascalientes, México. El conjunto consta de 26 casos descritos por once características divididos en 11 casos graves, 14 moderados y uno leve. La cantidad de instancias disponibles responde a la baja incidencia de la patología, la cual se diagnostica en uno de cada 10 mil nacimientos, mayoritariamente en varones [326].

Hasta este punto del estudio, se cuenta con dos matrices de aprendizaje. Como se recordará, la matriz de aprendizaje representa el insumo para la búsqueda exhaustiva de testores típicos. Dado que en ambos escenarios los datos son descritos por valores continuos, el proceso de colección de datos incluye un preprocesamiento que consistió en la discretización. Lo anterior, permitió que los registros tomaran un número limitado de estados facilitando el procesamiento posterior. La discretización se realizó de forma supervisada basada en entropía, es decir, se consideró la clase y su relación con cada variable involucrada [319].

De acuerdo con la Figura 47, el siguiente paso del estudio consistió en la búsqueda exhaustiva de los conjuntos de testores típicos correspondientes a ambos escenarios de experimentación. El proceso exhaustivo para la búsqueda de testores se describe detalladamente en la sección 2.7.2.

Como siguiente paso, se implementó un modelo de AG y un modelo de EDA. Para el AG, se utilizaron los operadores de evaluación, selección, cruce y mutación [323], [327]. Para el caso del EDA se sustituye el cruce y mutación por los operadores de estimación y muestreo para la generación de nuevas poblaciones [328], [329].

En ambos casos, la función de evaluación hace uso de la matriz básica encontrada en el paso anterior para permitir que ambas metaheurísticas identifiquen soluciones testor. En este caso, si la solución es calificada como testor, la función de costo se eleva en 10. En cambio, si la solución evaluada no resulta testor, la función de costo no es modificada.

Tal como se mencionó al inicio de esta sección, ambas metaheurísticas integraron el operador de alteración (OA). Este representa un enriquecimiento en la búsqueda de testores al encontrar los testores típicos inmersos en una solución particular. La inclusión del OA debe su importancia a la factibilidad de que la metaheurística se transforme en una búsqueda aleatoria, lo que implicaría no obtener los testores típicos asociados a la matriz de aprendizaje del problema. El OA trabaja sobre las soluciones evaluadas para analizar su vecindad en búsqueda de mejores soluciones.

```

BEGIN /* Operador de Alteración*/
  Sobrevivientes[] = NULL
  i=1
  REPEAT for l = 1, 2, ... hasta l = Número de soluciones en el conjunto
    Pivote = Solución l
    IF Solución l es testor THEN
      número de pruebas = (número bits 1 en Solución l * porcentaje de alteración) / 100
      REPEAT for m = 1, 2, ... hasta m = número de pruebas
        Seleccionar aleatoriamente un bit 1 del Pivote sin repetir
        Solución l' = Pivote con bit 1 seleccionado cambiado a bit 0.
        IF Solución l' es testor THEN
          Pivote = Solución l'
        END IF
      END REPEAT
    ELSE
      número de pruebas = (número bits 0 en Solución l * porcentaje de alteración) / 100
      REPEAT for m = 1, 2, ... hasta m = número de pruebas
        Seleccionar aleatoriamente un bit 0 del Pivote sin repetir
        Solución l' = Pivote con bit 0 seleccionado cambiado a bit 1.
        IF Solución l' es testor THEN
          Pivote = Solución l'
        END IF
      END REPEAT
    END IF
    Sobrevivientes[i] = Pivote
    i = i + 1
  END REPEAT
END

```

Figura 48. Algoritmo interno del operador de alteración. Publicado en [320].

La Figura 48 describe el funcionamiento del OA el cual, requiere como parámetro un porcentaje de alteración (PA) que es utilizado para determinar el número de vecinos a analizar por solución evaluada. El OA comienza tomando la solución l como pivote. En caso de que el pivote sea testor, el número de pruebas está dado por el número de bits 1 (presencia de la característica) y el valor del PA. En cada prueba se selecciona aleatoriamente (sin repetición) un bit 1 y se reemplaza por 0, de manera que se elimina la característica del subconjunto resultado en una solución l' . Si la solución l' resulta testor, se asigna como nuevo pivote para continuar las pruebas. En caso contrario, la solución l' es ignorada y el algoritmo mantiene el pivote.

Para el caso de que el pivote no sea testor, el número de pruebas está dado por el número de bits 0 y el valor del PA. En esta ocasión, un bit 0 es seleccionado y

reemplazado por un bit 1, agregando la característica al subconjunto creando una solución l' . Dicha solución es evaluada, si resulta ser un testor, la solución l' se toma como pivote y, en caso contrario, se ignora.

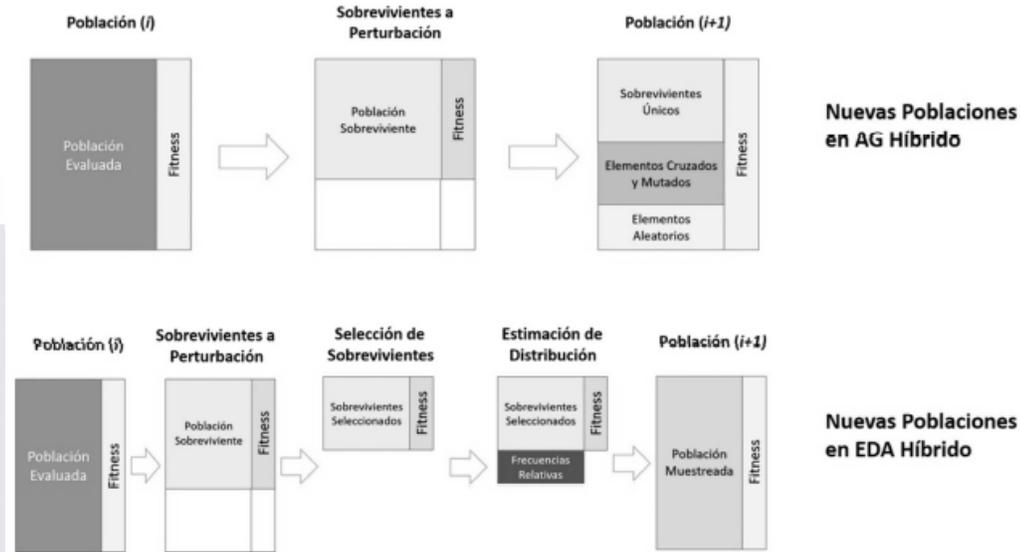


Figura 49. Generación de nuevas poblaciones en metaheurísticas híbridas. Publicado en [320].

Al final del proceso, se cuenta con el denominado conjunto sobreviviente, compuesto únicamente de soluciones testor. Este conjunto forma parte de la nueva población de soluciones. Como se muestra en la Figura 49, cada una de las metaheurísticas utilizan sus operadores habituales para completar la población de descendientes. En el caso del AG híbrido, las nuevas poblaciones se constituyen a partir de soluciones únicas del conjunto sobreviviente, emulando la implementación de elitismo; un conjunto obtenido por selección, cruce y mutación; y finalmente, un conjunto de soluciones generado aleatoriamente para mantener la diversidad de soluciones.

Para el EDA híbrido (Figura 49), las poblaciones se conforman de soluciones resultantes del operador de muestreo. Para ello, se selecciona aleatoriamente un porcentaje de las soluciones sobrevivientes dando mayor probabilidad a las

soluciones mejor evaluadas. A partir de ello, se estima la distribución $p_l(x)$ utilizando la función de distribución UMDA dada por la ecuación 42.

$$p_l(x) = p(x|D_{l-1}^{Se}) = \prod_{i=1}^n p_l(x_i) = \prod_{i=1}^n \frac{\sum_{j=1}^N \delta_j(X_i = x_i|D_{l-1}^{Se})}{N} \quad (42)$$

Para el paso tres de la Figura 47, se definieron los parámetros comunes para ambas Metaheurísticas, definidos de acuerdo con la metaheurística y el escenario de experimentación. Para los pasos cuatro y cinco, ambas metaheurísticas híbridas se sometieron a un proceso de afinación para cada escenario con el objetivo de identificar los valores de sus parámetros para los cuales, presentan un mejor desempeño en la búsqueda de testores típicos. El proceso de afinación consistió en un diseño de experimentos factorial con 30 réplicas.

Para el paso seis, el AG híbrido y el EDA híbrido fueron contrastados en términos de porcentaje de testores típicos encontrados, porcentaje de testores encontrados, el tiempo y el número de iteraciones realizadas. De esta manera, se determinó la metaheurística con mejor respuesta en cada escenario. Finalmente, en el paso siete se expresan conclusiones desde el punto de vista médico y computacional.

La Tabla 11 describe los testores típicos encontrados para células de cáncer de mama y hemofilia. Los testores típicos, en ambos casos, se describen mediante el peso informacional (PI) descrito en la sección 2.7 como una medida de significancia para cada característica. Esto significa que entre más aparezca una característica en diferentes testores típicos, más importante es para distinguir objetos pertenecientes a diferentes clases [330]. Para el caso de las células de cáncer de mama, se obtuvieron únicamente dos testores típicos que representan dos subconjuntos de características con los que es posible clasificar una nueva estancia de célula como benigna o maligna. De acuerdo con la Tabla 11, muestran un PI de 100%, lo que significa que son características imprescindibles para la clasificación de estancias nuevas. Sin embargo, el radio y el perímetro presentan un PI de 50% lo que da la posibilidad de clasificar una nueva instancia de célula desconociendo una de estas variables, pero no ambas.

Tabla 11. Escenarios de experimentación, características y pesos informacionales.
Publicado en [320].

PI (cáncer de mama)		
Característica	Descripción	PI
Radio	Longitud promedio del límite al centro de la célula.	50%
Textura	Varianza en las intensidades de escala de grises en los píxeles de la célula.	100%
Perímetro	Contorno de la célula.	100%
Área	Píxeles dentro de la célula.	50%
Lisura	Variación local en las longitudes del radio.	100%
Compacidad	$(\text{perímetro}^2) / \text{área}$	100%
Concavidad	Número y severidad de las concavidades en el núcleo.	100%
Puntos cóncavos	Número de concavidades en el contorno.	100%
Simetría	Diferencia de longitudes a partir de una línea central.	100%
Dimensión fractal	Aproximación de costa de Mandelbrot.	100%
PI (hemofilia)		
Característica	Descripción	PI
Edad	Años cumplidos.	23.08%
IMC	Índice de masa corporal.	61.54%
Tipo de Enfermedad	Hemofilia A o B.	23.08%
Artropatía	Si presenta daños articulares.	7.69%
Articulaciones con daño	Número de articulaciones dañadas.	38.46%
VIH	Presenta virus VIH.	23.08%
VHC	Presenta hepatitis C.	15.38%
VHB	Presenta hepatitis B.	15.38%
Inhibidores	Presenta anticuerpos a los factores de coagulación.	100%
Hemorragias al año	Numero de hemorragias anuales.	38.46%
Modalidad de tratamiento	Modalidad de suministro de factor de coagulación.	53.85%

Para el caso de hemofilia, se identificaron trece testores típicos descritos por su PI en la Tabla 11. Como se puede observar, la variable inhibidores obtuvo un 100% de PI lo que la vuelve imprescindible para clasificar casos de hemofilia. En caso contrario, la característica artropatía tiene la posibilidad de ser descartada debido a su bajo valor de PI y a que su información está contenida en la variable articulaciones con daño la cual, presenta un valor de PI mayor.

Tabla 12. Factores y niveles del diseño de experimentos. Publicado en [320].

AG		
Patología	Cáncer de mama	Hemofilia
Parámetros	Valores	Valores
Tamaño de población	10, 20, 40, 60, 80	700, 750, 800, 850,900
Porcentaje de alteración	10, 15, 20, 25, 30	10, 15, 20, 25, 30
Porcentaje de mutación	5, 8, 10, 12	5, 8, 10, 12
Iteraciones realizadas	50, 75, 100, 150	10, 15, 20, 25
EDA		
Patología	Cáncer de mama	Hemofilia
Parámetros	Valores	Valores
Tamaño de población	10, 20, 40, 60, 80	700, 750, 800, 850,900
Porcentaje de alteración	10, 15, 20, 25, 30	10, 15, 20, 25, 30
Porcentaje de selección	20, 30, 40, 50	20, 30, 40, 50
Iteraciones realizadas	50, 75, 100, 150	10, 15, 20, 25

Por su parte, la Tabla 12 muestra los parámetros para el diseño de experimentos factorial utilizado para ajustar las metaheurísticas considerando las resultantes: porcentaje de testores típicos encontrados, porcentaje de testores encontrados, iteraciones realizadas y tiempo requerido. El proceso de afinación consistió en la ejecución de 400 experimentos replicados 30 veces formando 400 grupos independientes. Lo anterior aplicado a cada algoritmo con cada patología. Una vez concluida la ejecución de los experimentos y sus réplicas, se probó igualdad de varianzas entre los grupos de réplicas por medio de la prueba Levene y de normalidad con Kolmogorov-Smirnov.

Afinación de parámetros del modelo AG híbrido

La Tabla 13 muestra que, para el caso del AG híbrido aplicado a las estancias de células de cáncer de mama, los 400 grupos no presentan homocedasticidad ni siguen una distribución normal, por lo que se optó por una prueba Kruskal-Wallis determinando la existencia de diferencia significativa entre los grupos. Dado este resultado, se realizaron pruebas U-Mann Whitney con un nivel de significancia de 0.05. Desde el punto de vista del porcentaje de testores típicos encontrados, se observó que los grupos con promedio entre el 96.6% y el 100% de los testores típicos son estadísticamente similares. Escenario similar a lo sucedido con respecto del porcentaje de testores encontrados.

Tabla 13. Pruebas estadísticas y mejores experimento de AG híbrido para células de cáncer de mama y casos de hemofilia. Publicado en [320].

Mejores Experimentos AG								
Experimento	Parámetros				Variables de salida			
	Tam. Pob.	% Alt.	Prob. Mut.	Max. Iter.	T. típicos	Testores	Iter.	Tiempo
AG en cáncer de mama	10	10	5	150	100%	100%	11.27	0.1687s
AG en hemofilia	850	10	12	10	100%	76.12%	2.73	3.0471s
Pruebas Estadísticas (Cáncer de mama)								
Prueba					Conclusión			
Levene con $\alpha=0.05$					No existe homocedasticidad.			
Kolmogorov-Smirnov con $\alpha=0.05$					Los grupos no siguen distribución normal			
Kruskal Wallis con $\alpha=0.05$					Existe diferencia significativa en los 400 grupos respecto a las cuatro variables			
Pruebas Estadísticas (Hemofilia)								
Prueba					Conclusión			
Levene con $\alpha=0.05$					No existe homocedasticidad.			
Kolmogorov-Smirnov con $\alpha=0.05$					Los grupos no siguen distribución normal para las variables de testores, el tiempo y el número de iteraciones.			
Kruskal Wallis con $\alpha=0.05$					No existe diferencia significativa respecto a los testores típicos encontrados. En cambio, existe diferencia significativa respecto al resto de las variables.			

Los resultados obtenidos permitieron observar que el AG híbrido propuesto es sensible a la cantidad de individuos respondiendo mejor a poblaciones de 10, 40 y 80 individuos. De igual manera, la metaheurística se ve afectada por el valor del PA al presentar mejores resultados con 10, 15, 20 y 30%. Sin embargo, es interesante recalcar que el AG híbrido presenta inmunidad al resto de los parámetros. Asimismo, la Tabla 13 muestra la configuración de parámetros con mejor desempeño para el AG híbrido aplicado a células de cáncer de mama el cual, asegura conjuntos completos de testores típicos en menor tiempo posible.

En el caso del AG híbrido aplicado a casos de hemofilia, los grupos no presentan homocedasticidad y, tal como se muestra en la Tabla 13, tampoco presentan normalidad en su distribución. Debido a ello, se realizó una prueba de Kruskal Wallis que estableció que los grupos analizados no presentan diferencia significativa respecto a los testores típicos encontrados, dado el hecho de que el AG híbrido fue capaz de encontrar el 100% de testores en los 400 grupos. En cambio, se muestra una diferencia significativa en el total de grupos respecto del resto de las variables.

El estadístico U-Mann Whitney con un nivel de significancia de 0.05, concluyó que los grupos que encontró que grupos que encontraron entre el 73.68 y 76.12% de los testores son estadísticamente iguales. Por otro lado, el AG híbrido presenta sensibilidad al tamaño de la población mejorando su desempeño con 800, 850 y 900 individuos. Además, resulta determinante el valor de PA sea un 10% para mejorar el desempeño de la metaheurística. Finalmente, el AG no es influenciado por el resto de los parámetros. En la Tabla 13 se muestran los valores de los parámetros que permiten un mejor de rendimiento del AG híbrido aplicado a casos de hemofilia en la Tabla 13.

Afinación de parámetros del modelo EDA híbrido

Al igual que en el caso anterior, para el EDA híbrido se realizó la ejecución de 400 experimentos con 30 réplicas, formando 400 independientes para cada patología. En la Tabla 14 se muestran los estadísticos realizados, así como las configuraciones con mejor desempeño en la búsqueda de testores típicos.

Tabla 14. Pruebas estadísticas y mejores experimento de AG híbrido para células de cáncer de mama y casos de hemofilia. Publicado en [320].

Mejores Experimentos EDA								
Experimento	Parámetros				Variables de salida			
	Tam. Pob.	% Alt.	% Selec.	Max. Iter.	T. típicos	Testores	Iter.	Tiempo
EDA en cáncer de mama	40	20	40	100	100%	100%	4.6	0.1287s
EDA en hemofilia	900	10	30	20	100%	83.3%	2.53	2.478s
Pruebas Estadísticas (Cáncer de mama)								
Prueba					Conclusión			
Levene con $\alpha=0.05$					No existe homocedasticidad.			
Kolmogorov-Smirnov con $\alpha=0.05$					Los grupos no siguen distribución normal			
Kruskal Wallis con $\alpha=0.05$					Existe diferencia significativa en los 400 grupos respecto a las cuatro variables.			
Pruebas Estadísticas (Hemofilia)								
Levene con $\alpha=0.05$					No existe homocedasticidad.			
Kolmogorov-Smirnov con $\alpha=0.05$					Los grupos no siguen distribución normal para las variables de testores, el tiempo y el número de iteraciones.			
Kruskal Wallis con $\alpha=0.05$					No existe diferencia significativa respecto a los testores típicos encontrados. A su vez, existe diferencia significativa en cuanto al resto de las variables.			

Para el caso de células de cáncer de mama, los grupos no presentan homocedasticidad ni normalidad en su distribución. Dada la existencia de diferencia entre los 400 grupos, se realizaron pruebas U-Mann Whitney. Dichas pruebas mostraron que los grupos que encontraron entre el 95 y 100% de los testores típicos son estadísticamente similares sin que los valores de sus parámetros influyeran. Sin

embargo, al hacer una observación empíricamente se encontró que el modelo de EDA híbrido es influenciado por los valores de población de 40, 60 y 80 individuos. Lo mismo sucede con PA de 10, 15 y 20% para mejorar el desempeño de la metaheurística.

Bajo el contexto de los casos de hemofilia (ver Tabla 14), no se presenta homocedasticidad ni distribución normal en los grupos de experimentos. Según una prueba Kruskal Wallis, se encontró la existencia de diferencia respecto al porcentaje de testores, iteraciones y el tiempo. En cambio, no existe diferencia en el porcentaje de testores típicos encontrados dado el hecho que el total de los grupos encontraron el 100% de los testores típicos asociados. Bajo este contexto, se realizaron pruebas U-Mann Whitney para los parámetros de porcentaje de testores. Esto resultó en los grupos que encontraron en promedio entre el 80.85% y 83.5% son estadísticamente similares. Finalmente, se encontró que el modelo EDA híbrido es sensible al tamaño de la población al requerir 800, 850 y 900 individuos para mejorar los resultados. Lo mismo para el parámetro PA requiriendo, estrictamente, un 10% de alteración.

Contrastación de metaheurísticas

Tomando los parámetros que permitieron un mejor resultado en la búsqueda de testores típicos, se procedió a la realización de nuevas pruebas para contrastar el EDA y el AG híbridos para determinar cuál beneficia más a cada problema. Dichos valores se pueden apreciar en las Tablas 13 y 14.

La Tabla 15 expone los resultados de las nuevas ejecuciones y los resultados de las pruebas estadísticas realizadas. Para las células de cáncer de mama, existe homocedasticidad en cuanto al porcentaje de testores típicos encontrados, sin embargo, no existe homocedasticidad para el resto de las resultantes. Por su parte, la prueba de Kolmogorov-Smirnov encontró que los grupos siguen una distribución normal. Mientras que las pruebas de Kruskal Wallis arrojaron la existencia de diferencias significativas para el tiempo utilizados y las iteraciones realizadas.

Tabla 15. *Contrastación de metaheurísticas híbridas en el contexto de cáncer de mama y hemofilia. Publicado en [320].*

		Variables de salida				
Patología	Experimento	T. típicos	Testores	Iter.	Tiempo	
Cáncer de mama	AG	100%	94.45%	14.03	0.9909s	
	EDA	100%	97.78%	4.23	0.2281s	
	Pruebas Estadísticas					
	Prueba		Conclusión			
	Levene con $\alpha=0.05$		Existe homocedasticidad respecto al porcentaje de testores, pero no respecto al resto de las variables.			
	Kolmogorov-Smirnov con $\alpha=0.05$		Los grupos no siguen una distribución normal.			
	Kruskal Wallis con $\alpha=0.05$		Existe diferencia significativa respecto al tiempo e iteraciones, pero no respecto a testores y testores típicos.			
		Experimento	T. típicos	Testores	Iter.	Tiempo
Hemofilia	AG	100%	72.54%	2.33	2.8939s	
	EDA	100%	78.76%	2.33	2.7623s	
	Pruebas Estadísticas					
	Prueba		Conclusión			
	Levene con $\alpha=0.05$		Existe homocedasticidad respecto al tiempo y las iteraciones, pero no respecto de testores y testores típicos.			
	Kolmogorov-Smirnov con $\alpha=0.05$		Los grupos siguen una distribución normal respecto a los testores, pero no en el resto de las variables.			
	Kruskal Wallis con $\alpha=0.05$		Existe diferencia significativa respecto a los testores encontrados, pero no en el resto de las variables.			

De acuerdo con la aplicación de pruebas U-Mann Whitney, los grupos de EDA y AG híbridos aplicados a células de cáncer de mama son estadísticamente iguales con respecto al porcentaje de testores y testores típicos encontrados. En cambio, difieren estadísticamente en tiempo y en las iteraciones realizadas por lo que el EDA híbrido destaca minimizando ambas resultantes. Por lo tanto, el EDA es superior empírica y estadísticamente al encontrar el 100% de los testores típicos con menor requerimiento de tiempo e iteraciones.

Para el contexto de los casos de hemofilia, los grupos de EDA y AG no presentan homocedasticidad respecto al número de testores y testores típicos encontrados. A su vez, no muestran una distribución normal respecto del número de testores encontrados. Por otro lado, una prueba de Kruskal Wallis mostró la existencia de diferencia significativa en cuanto a los testores encontrados. Al aplicar pruebas U-Mann Whitney para cada una de las resultantes, se encontró que ambas metaheurísticas son estadísticamente similares en el número de testores típicos encontrados, el número de iteraciones realizadas y el tiempo requerido. Finalmente, el EDA híbrido destaca como mejor alternativa al presentar un mayor número de testores típicos encontrados y un menor requerimiento de tiempo.

Como se pudo observar, la inclusión del operador de alteración en ambas metaheurísticas resultó beneficioso en la búsqueda de testores típicos en cada uno de los casos de estudio. Pues, debido a la naturaleza exponencial de la búsqueda de testores típicos, resulta muy probable que las metaheurísticas en su concepción pura, no puedan converger adecuadamente. Así, bajo el estudio realizado en este apartado se prueba satisfactoriamente la efectividad del operador de alteración permitiendo la localización de testores típicos en tiempos polinomiales. Cabe recalcar, que la aplicación de las metaheurísticas AG y EDA con el operador propuesto no es exclusiva para contextos médicos, pues, es posible aplicar selección de subconjuntos de características en conjuntos de datos provenientes de otras áreas del conocimiento. No obstante, es importante recordar que la discretización de los datos fue crucial para la realización de este estudio.

Primera aplicación de la teoría de testores

Este primer estudio pertenece a la publicación “Feature Subset Selection in Electroencephalographic signals using typical testors” presentado para el Hybrid Intelligent Systems (HIS) Workshop del MICAI 2021 (ver Anexo A.7)

Para realizar el cálculo de testores típicos se siguieron las fases presentadas en la Figura 50. La adquisición de señales EEG-MI corresponde al conjunto de datos obtenido en la Fase 3, descrito en la sección 4.3.1.

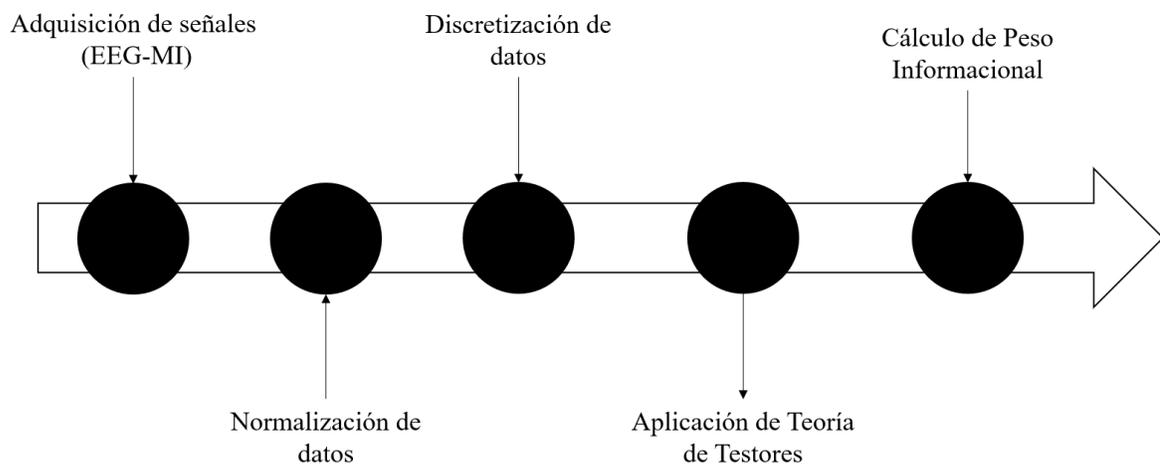


Figura 50. Cálculo de testores típicos en señales EEG-MI. Publicado en Anexo A.7

Como se recordará, el conjunto de datos constó de 23,846 registros tomados de seis sujetos de prueba por medio de 6 muestreos de cinco segundos. El repositorio consta específicamente de 12,190 registros correspondientes a “abrir” la mano y 11,656 a la intención de “cerrar” la mano.

De acuerdo con la Figura 50, el siguiente paso fue la normalización de los datos. Pues, como se indicó en la sección 4.3.2, los datos no presentan una relación lineal. Por lo tanto, con la normalización se tuvo como objetivo evitar que ninguno de los catorce canales que describen la señal tenga mayor influencia sobre las demás. Para ello, se aplicó la normalización tipo Z-score dada por:

$$new\ value = \frac{X - \mu}{\sigma} \quad (43)$$

Por su parte, la discretización del repositorio permitió la conversión de los datos a una forma categórica que facilita la obtención del conjunto de testores utilizando únicamente diferencias absolutas (ver apartado 2.7.1). Para llevar a cabo este proceso, se utilizó la herramienta KbinsDiscretizer de la librería Sklearn de Python que permite la conversión automática de una variable en un número de intervalos determinado y una estrategia concreta [331]. Específicamente, se utilizó un valor de 5 intervalos (n_bins); un encode onehot, para codificar el resultado; y la estrategia de quantile para definir el número de valores en cada intervalo especificado.

La fase del cálculo de testores típicos inició con un proceso de muestreo aleatorio en el cual se extrajeron mil registros de la base de datos original, conformada por 500 registros de cada una de las clases. Por su parte, la búsqueda de testores típicos se realizó utilizando el modelo exhaustivo por medio de la librería de Python testorestípicos.py desarrollada por el Maestro en Informática y Tecnologías Computacionales Daniel Alejandro Barajas Aranda et al., estudiante de doctorado de la Universidad Autónoma de Aguascalientes y publicada en [332].

Tabla 16. Testor típico en señales EEG-MI con intención de movimiento. Publicado en Anexo A.7.

Testores														
AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4	Tipo
1	1	1	1	1	1	1	1	1	1	1	0	1	1	TT
1	1	1	1	1	1	1	1	1	1	1	1	1	1	T

En la Tabla 16 se exponen el testor y el testor típico encontrados. Como se puede observar, el testor típico es representado por valores binarios donde un valor de cero representa la ausencia de la variable, es decir, no provee información relevante. Por otro lado, el valor de uno significa que la variable contiene información esencial.

Para este estudio se encontraron dos testores de los cuales, uno es testor típico. Por lo tanto, este testor típico representa el subconjunto mínimo necesario para distinguir objetos de diferentes clases (“abrir” y “cerrar”).

Tabla 17. *Peso informacional. Publicado en Anexo A.7*

Canal	PI	Canal	PI
AF3	100%	O2	100%
F7	100%	P8	100%
F3	100%	T8	100%
FC5	100%	FC6	100%
T7	100%	F4	0%
P7	100%	F8	100%
O1	100%	AF4	100%

La fase final del proceso de la Figura 50 es el cálculo del peso informacional descrito en el apartado 2.7.2 y la ecuación 2. La Tabla 17 muestra el peso informacional calculado a partir del testor típico resultante. Cada porcentaje representa una medida de significancia para cada característica o canal, involucrado. En este sentido, 13 de 14 canales resultan ser esenciales con un peso informacional de 100%, mientras que el canal F4 con un 0% de peso informacional no representa información relevante para un proceso de clasificación. Por lo tanto, esta característica puede ser omitida o desconocida en un proceso de clasificación.

De esta manera, el objetivo de reducir la dimensionalidad del problema se logra describiendo las clases con un número menor de características, haciendo la representación de objetos más sencilla y como soporte para sistemas de clasificación.

Segunda aplicación de la teoría de testores

Se realizó un segundo acercamiento al cálculo de testores típicos tomando como base el mismo repositorio descrito en el apartado 4.3.1 y el procedimiento de la Figura 50. En esta ocasión se tomaron dos muestras aleatorias de 200 registros, tanto para abrir como para cerrar la mano derecha, dando una muestra aleatoria de 400 registros. Esto con base al cálculo de una muestra representativa dada por la ecuación 43. Utilizando el total de registros (23,846) como tamaño de la población, un nivel de confianza del 95%, con una puntuación $z = 1.96$ y un margen de error del 5%, dando como resultado un tamaño de muestra de 379 registros.

$$muestra = \frac{\frac{z^2 * p(1 - p)}{e^2}}{1 + \left(\frac{z^2 * p(1 - p)}{e^2 N}\right)} \tag{44}$$

La reducción del tamaño de muestra se debe a que el cálculo de los testores típicos es un algoritmo exponencial, por lo tanto, el costo computacional de extraer un conjunto de testores se reduce.

A su vez, el proceso de discretización (ver Figura 50) se realizó con la librería `KbinsDiscretizer` modificando sus parámetros a `n_bins = 5`, `encode = 'ordinal'`, y `startegy = 'kmeans'`. De igual manera, se utilizó la librería `testorestípicos.py` de Daniel Barajas et al [332].

Tabla 18. Segundo conjunto de testores típicos y el cálculo de peso informacional. Publicada en Anexo A.8.

Testores Típicos													
AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4
1	1	1	1	1	0	0	0	1	1	1	0	0	1
1	1	1	1	1	1	1	0	0	1	0	0	0	1
1	1	1	1	1	1	0	0	1	1	0	0	0	1
1	1	0	1	1	0	1	0	1	1	1	0	1	1
1	1	0	1	1	0	1	1	1	1	1	0	0	1
100%	100%	60%	100%	100%	40%	60%	20%	80%	100%	60%	0%	20%	100%

La Tabla 18 muestra la obtención de un conjunto de cinco nuevos testores típicos junto con los valores obtenidos de peso informacional (ecuación 2). Como se mencionó anteriormente, el valor del peso informacional se interpreta como una medida de significación para cada una de las características. Es decir, cuanto mayor sea su valor de peso informacional, mayor será la relevancia en un proceso de clasificación. Tal es el caso de las características de la Tabla 18, donde se pueden observar seis de ellas (AF3, F7, FC5, T7, T8, AF4) con un valor de peso informacional del 100%, lo que significa que conocer sus valores es indispensable para decidir si es una señal con intención de abrir o cerrar la mano. Por otro lado, la característica F4 obtuvo un valor de peso informacional de cero, lo que significa que se puede descartar porque su valor no genera relevancia en el proceso de clasificación.

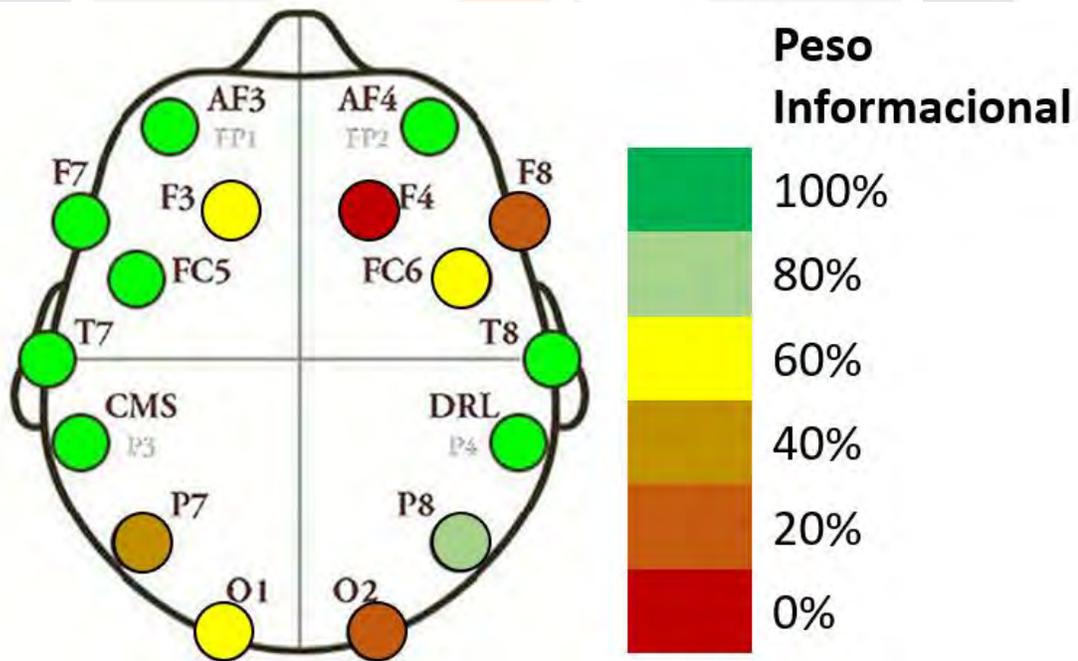


Figura 51. Comportamiento del peso informacional en los electrodos del EPOC+. Imagen tomada de [150] y modificada para presentar pesos informacionales.

La Figura 51 muestra el comportamiento de los electrodos del Emotiv EPOC+, descrito en la sección 4.2.1, de acuerdo con su valor de peso informacional. Como es posible de observar, los electrodos con un 100% de peso informacional se

concentran a la altura de los lóbulos frontal, parietal y temporal izquierdos. Lóbulos encargados de la coordinación y planeación de movimiento motriz, la imaginación, la identificación y sensaciones corporales, así como tareas asociadas a la memoria. Para más información, el lector puede consultar la sección 2.2.

Así mismo, como se menciona en los capítulos 2.2 y 2.3, el hemisferio izquierdo está asociado con el control de las extremidades derechas. Por lo que resulta lógico el hecho de que los nodos del hemisferio izquierdo resulten imprescindibles, de acuerdo con su peso informacional y sus funciones relacionadas al movimiento motriz, para diferenciar entre la intención de abrir y la intención de cerrar la mano derecha.

4.4 Fase 4

4.4.1 Implementación de algoritmos ML con repositorio de estado de ojo

Como parte de la búsqueda de repositorios con señales EEG realizada en la Fase 2, se dispone de una base de datos obtenida de la UCI Machine learning repository con señales de estado del ojo: abierto y cerrado [315]. Repositorio descrito en la sección 4.2.2. Este repositorio fue utilizado para la implementación de un modelo de Naive Bayes (sección 2.12.1) y un primer acercamiento a una red neuronal artificial (sección 2.12.2).

Implementación de Naive Bayes (clasificador bayesiano simple)

El primer clasificador implementado fue el clasificador bayesiano simple o Naive Bayes, descrito anteriormente en la sección 2.12.1. Este clasificador fue entrenado y validado a partir del repositorio del estado del ojo. El clasificador bayesiano simple recibió un total de 14,980 instancias de las cuales, cerca del 80% fueron utilizados

para construir el modelo bayesiano simple en su etapa de entrenamiento y el 20% restante se utilizaron para validar la validación del obtenido. Tal como se describe en la sección 2.11.1 en la Figura 27 específicamente.

Tabla 19. Tabla de confusión para el clasificador bayesiano simple.

		Predicción	
		Clase OA	Clase OC
Valores reales	Clase OA	1610 (54.52%)	27 (0.91%)
	Clase OC	141 (4.77%)	1175 (39.79%)
Nomenclatura	OA	Ojo abierto	
	OC	Ojo cerrado	

La Tabla 19 muestra la matriz de confusión obtenida a partir de la etapa de validación del modelo de clasificador bayesiano simple. Como se puede observar, se muestra la relación entre las predicciones realizadas por el modelo y los valores reales esperados. Para más información, el lector puede consultar la sección 2.11.1.

Tabla 20. Métricas de desempeño del clasificador bayesiano simple.

Métrica	Valor
Exactitud	94.31%
Precisión Ojo Cerrado	89.29%
Precisión Ojo Abierto	98.35%
Razón de Falsos OA	1.65%
Razón de Falsos OC	10.71%
Número de registros	14,980
Datos de aprendizaje (80%)	12,027
Datos de validación (20%)	2,953

Asimismo, la Tabla 20 muestra las métricas derivadas de la matriz de confusión, las cuales describen con mayor detalle el desempeño del clasificador. En este caso, se muestra una exactitud del 94.31%. Sin embargo, cabe recalcar que muestra muy

buen equilibrio al ser capaz de distinguir ambas clases con 89.29% y 98.35% para ojo cerrado y ojo abierto respectivamente. Por consiguiente, muestra una mínima tasa de falsas clasificaciones. A su vez, se muestra el total de registros utilizados y el muestreo realizado para obtener el conjunto de datos de aprendizaje (80%) y el conjunto de datos de validación (20%).

Cabe destacar que, al momento de la implementación de este clasificador no se aplicó algún preprocesamiento al conjunto de datos. Es así, que se muestra la robustez y sencillez que distinguen al clasificador bayesiano simple al ser utilizado como punto de comparación en la implementación de otros algoritmos de aprendizaje automático.

Implementación de una red neuronal artificial

Por otro lado, se implementó un primer acercamiento de red neuronal artificial multicapa en su versión densa, es decir, cada neurona de una capa está conectada con todas las neuronas de la capa siguiente. Al igual que en el caso anterior, el conjunto de datos del repositorio no fue sometido a ningún preprocesamiento.

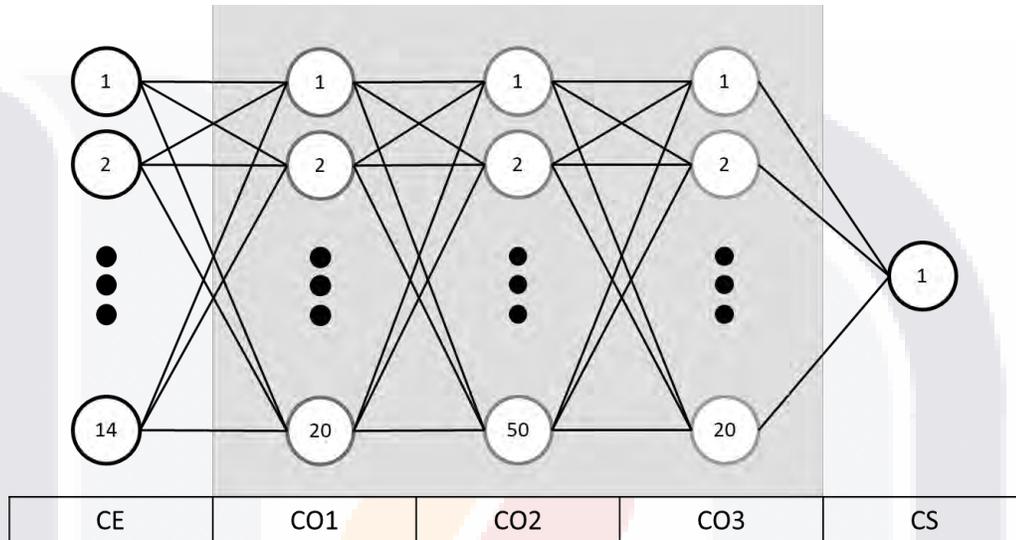


Figura 52. Configuración de red neuronal multicapa en su primer acercamiento.

Ésta primera red neuronal se construyó utilizando las librerías de tensorflow de Google para su explotación en aplicaciones Python. En la Figura 52 se muestra la configuración de la red neuronal, la cual consta de una capa de entrada con 14 neuronas, una por cada nodo/electrodo del dispositivo de captura de señales EEG, utilizando la función de activación relu. Constó, además, de una primera capa oculta con 20 neuronas y la función de activación relu, una segunda capa oculta con 50 neuronas y la función de activación de tangente hiperbólica y una tercera capa oculta con 20 neuronas y la función de activación relu. Finalmente, una capa de salida con una única neurona con la función de activación sigmoial. Esta configuración de red neuronal ejecuto un total de 700 épocas y logró una exactitud del 94.44%.

4.4.2 Afinación de parámetros en modelos de aprendizaje automático

Para este estudio se hizo uso del repositorio preliminar de intención de movimiento descrito en la Tabla 21, conformado por señales propias sobre la intención de abrir y cerrar la mano derecha. Para más información, consultar la sección 4.2.4.

En este apartado se describe el ajuste de parámetros aplicado a dos algoritmos de aprendizaje, las redes neuronales artificiales (RNA) y las máquinas de soporte vectorial (SVM), ambos descritos en los apartados 2.12.2 y 2.12.3 respectivamente. Los resultados obtenidos en esta sección fueron publicados en la revista Research in Computer Science con el título “Contrastación de algoritmos de aprendizaje automático para la clasificación de señales EEG”, volumen 149, número 8, en el año 2020 (ver Anexo A.4). El objetivo de este estudio fue conocer la mejor configuración de parámetros en modelos de máquinas de soporte vectorial y de redes neuronales artificiales.

Tabla 21. Repositorio de datos para afinación de parámetros

Repositorio de señales EEG-MI 1	
Registros de cerrar mano	717
Registros de abrir mano	566
Total de registros	1,283

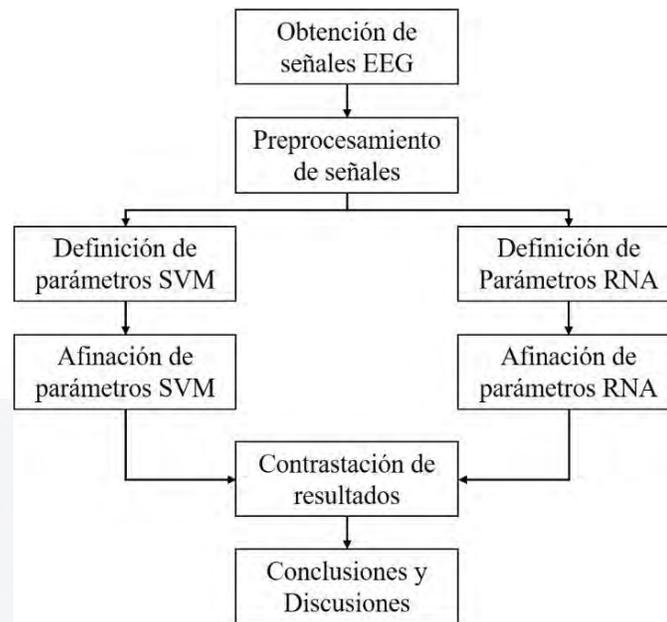


Figura 53. Ajuste de parámetros RNA y SVM para clasificar señales EEG. Publicado en [333].

Para realizar este ajuste, se utilizó un diseño de experimentos factorial con distintas configuraciones de parámetros y determinar cuáles permiten un mejor desempeño cada algoritmo y así, concluir con el más adecuado para clasificar señales EEG con intención de movimiento. Para ello, se siguió el diagrama expuesto en la Figura 53.

Como se mencionó anteriormente, para la obtención de las señales EEG con la intención de movimiento de la mano derecha (abrir y cerrar) se contó con el dispositivo comercial Emotiv EPOC+ utilizando la información de los 14 nodos disponibles. Cada muestra fue tomada con una duración de 15 segundos en la cual, se solicitaba al sujeto de prueba mantener la concentración en el movimiento específico. Tal como se describe en el apartado 4.2.3. Al final del muestreo se contó con los 1283 registros conformados por 566 correspondientes a abrir la mano y 717 a cerrar la mano de la sección 4.2.4.

Debido a la complejidad de los datos, se optó por realizar un trabajo de preprocesamiento. Dicho preprocesamiento consistió en trasladar los datos de

estudio a una escala común por medio de la normalización Z-score [285], [334] (Ver ecuación 42 de la sección 4.3.3).

Una vez que se contó con los datos normalizados, se realizó un diseño de experimentos. Para ello, se definieron los parámetros de entrada para los algoritmos de aprendizaje seleccionados: SVM y RNA. Para el caso de las SVM, los parámetros utilizados fueron: el kernel, el valor gamma y el valor C (ver Tabla 22).

Tabla 22. Parámetros SVM para la afinación de clasificación de intención de movimiento. Publicado en [333].

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

Específicamente, el kernel permite crear una nueva dimensión que facilite encontrar el hiperplano de solución óptima (HSO) [335]. Se seleccionaron los kernel rbf (Radial Basis Function) y poly (Polynomial) de acuerdo a los resultados obtenidos en [26] con 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 [271]. Los valores mostrados en la Tabla 22, se tomaron con base al valor defecto de sklearn, el cual es $1/n$, donde n es el número de características que se analizan [336].

Finalmente, el valor C controla las violaciones del margen que se toleran en el proceso de ajuste [277]. Se trata de un peso de regularización que permite que se cometan errores al clasificar. Al poseer un valor que tienda a infinito, la penalización del error será más severa. En cambio, si el valor disminuye, se permite mayor porcentaje de errores [271]. En este caso, los valores de C se eligieron de manera que pudieran explorar distintos niveles de la variable.

Al final de este diseño de experimentos se contó con 18 experimentos los cuales, fueron ejecutados 30 veces para posteriormente contrastarlos con los modelos RNA.

Para el caso de las redes neuronales artificiales (RNA), se diseñaron dos modelos. El primero consta de una RNA densa con solo una capa oculta y el segundo de 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. Además de que el uso de más capas y neuronas supone mayor costo computacional [337], [338].

Ambos modelos se componen de una capa de entrada con catorce neuronas, según el número de características a procesar; y una capa de salida con una única neurona con una 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. Los parámetros del primer modelo de RNA son el número de neuronas en la capa oculta, su función de activación, el número de épocas y el tamaño del lote (ver Tabla 23).

Tabla 23. Parámetros RNA para imaginación motora. Publicado en [333].

Modelo	Neuronas en capa oculta	Función de activación	Neuronas en capa oculta 2	Función de activación	N° 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					

Aunque existen diversas topologías de RNA, aún queda a consideración el número de neuronas en cada capa oculta [339]. En la literatura se pueden encontrar algunas reglas que sugieren puntos de partida con buenos resultados como el

propuesto por Lippmann en [340]. La propuesta consiste en que los problemas complejos pueden ser resueltos con una capa oculta con al menos tres veces el número de neuronas de entrada [337], [340]. Particularmente, para establecer los datos de la Tabla 23 se realizaron pruebas empíricas. En el caso del número de neuronas se tomó como punto de partida la regla de Lippmann.

Como se mencionó anteriormente, se diseñó un segundo modelo de RNA (ver Tabla 23) cuya diferencia radica en la adición de una segunda capa oculta, donde el número de neuronas es menor para ajustarse a la regla de la pirámide geométrica que establece que el número de neuronas ha de ser menor al número de entradas que en este caso es la capa oculta anterior [337], [338].

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

Como se hizo con las configuraciones del modelo de SVM, para los modelos de RNA se ejecutaron las 24 configuraciones de parámetros del modelo 1 y los 96 del modelo 2. A su vez, cada configuración fue ejecutada en 30 réplicas para formar grupos de experimentos y llevar a cabo una contrastación entre los tres modelos.

Para evaluar el desempeño de cada experimento y contrastar ambos algoritmos de aprendizaje automático se tomó como referencia la matriz de confusión (sección 2.11.1) de cada experimento, lo que permitió visualizar la distribución de los errores cometidos por un clasificador [341].

Como se mencionó anteriormente, cada configuración de parámetros en el modelo SVM y en los modelos de RNA se replicó en un total de 30 ocasiones independientes las cuales se contrastaron por medio de un análisis estadístico y se determinó qué modelo presenta un mejor desempeño en la clasificación de las señales EEG-MI.

Las salidas analizadas provienen de la matriz de confusión obtenida de cada modelo y sus réplicas. Las variables de salida fueron: la exactitud, la precisión

positiva, la precisión negativa, la razón de falsos positivos y la razón falsos negativos.

Tabla 24. Mejores modelos SVM y RNA. Publicado en [333].

Modelo	Configuración	E.	P (+)	P (-)	R. F(+)	R. F(-)
SVM	Kernel: rbf, Gama: 0.04, C: 200	0.9300	0.9306	0.9293	0.0706	0.0693
RNA 1 capa	C1:75, A: relu, Epoc: 100, batch: 5	0.9571	0.9560	0.9588	0.0411	0.0439
RNA 2 capas	C1: 75, A: relu, C2: 15, A: relu, Epoc: 100, batch: 5	0.9581	0.9607	0.9551	0.0448	0.0392

Los grupos de ambos modelos de RNA resultan ser equiparables estadísticamente en cuanto a exactitud, precisión negativa y la razón de falsos positivos. Dado lo anterior, se eligen el mejor grupo del modelo 1 (75 neuronas en capa oculta, activación relu, 100 épocas y un batch de 5) y del modelo 2 (75 neuronas en capa oculta, activación relu, 15 neuronas en la segunda capa oculta, activación relu, 100 épocas y un batch de 5) de forma concreta los cuales, se describen en la Tabla 24.

Por medio de una prueba U-Mann Whitney se contrastaron ambos grupos resultando en que son completamente equiparables estadísticamente. En este caso, se decide que la mejor opción es utilizar el modelo 1 de RNA debido a que su configuración es computacionalmente menos costosa.

Para el caso de los grupos de experimentos de SVM, las variables de salida tampoco siguen una distribución normal, por lo que se hace uso de estadística no paramétrica. La prueba Kruskal-Wallis resultó en que los conjuntos de experimentos son diferentes significativamente.

Al igual que en los modelos de RNA, se seleccionaron los cuatro mejores conjuntos que maximizan su exactitud y precisión (positiva y negativa), y minimizan la razón de falsos positivos y falsos negativos. Dichos conjuntos se analizaron con Kruskal-Wallis resultando en que existen diferencia significativa respecto al total de

las variables de salida. Debido a ello, de los cuatro mejores se decide contrastar los dos mejores por medio de U-Mann Whitney el cual, dio como resultado que ambos grupos son distintos estadísticamente. Por lo tanto, se elige como mejor el grupo con la configuración con kernel rbf, un valor de gamma de 0.04 y un valor C de 200 (ver Tabla 24) debido a que, de forma empírica maximiza la exactitud y la precisión positiva, además de que minimiza la razón de falsos negativos.

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 el caso de los modelos RNA se eligió la configuración de una sola capa oculta para contrastarse con el mejor modelo con mejor desempeño de las SVM. 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 24, el modelo RNA de una capa oculta maximiza la exactitud y la precisión tanto positiva y negativa; además de 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-MI. No obstante, hay algunas observaciones importantes al elegir un mejor modelo.

La primera de ellas es que los algoritmos de aprendizaje automático, tanto las máquinas de soporte vectorial como las redes neuronales artificiales, son muy robustos pudiendo adaptarse a distintos problemas en este caso, la clasificación de señales EEG-MI. Sin embargo, la tarea de ajustar los parámetros de los algoritmos de aprendizaje automático es crucial para obtener un buen desempeño. Es decir, se debe tener bien claro el objetivo que se busca y los recursos computacionales con los que se cuentan. Lo anterior 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. Un ejemplo claro son los modelos de RNA con una y dos capas ocultas. Ambos modelos obtuvieron un buen desempeño, incluso, se puede observar (ver Tabla 24) que el modelo de dos capas ocultas es superior en tres de las variables de salida. Sin embargo, el modelo de dos capas es más complejo y requiere un mayor costo

computacional y dado que ambos modelos son estadísticamente equiparables podemos optar por el modelo de una sola capa oculta a pesar de que su desempeño es mínimamente inferior pero un costo computacional menor.

En el caso de las máquinas de soporte vectorial se contrastaron los dos mejores grupos de experimentos. Ambos grupos resultan ser estadísticamente distintos, por lo tanto, se seleccionó el mostrado en la Tabla 24 debido a que es empíricamente superior en tres de las cinco variables de salida, al maximizar la exactitud y la precisión positiva, al tiempo que minimiza la razón de falsos negativos. En este caso, al ser diferentes es posible elegir entre uno y el otro dependiendo de la variable de salida que sea de mayor interés para quien realice el modelo. Pues el modelo de descartado (con kernel polinómico, gamma de 0.04 y valor C de 200) maximiza la precisión negativa y minimiza la razón de falsos positivos. Entonces, si el objetivo no es precisamente la exactitud esta configuración de parámetros es la mejor opción.

Finalmente, y de acuerdo con la Figura 53, se contrastó el mejor modelo del SVM y el modelo de una capa oculta de RNA, ambos descritos en la Tabla 24. Los modelos resultan ser distintos estadísticamente en las cinco variables de salida, por lo tanto, decidir entre un modelo y otro recae en el objetivo que se tenga, e incluso, puede ser de mucho interés la variable de tiempo. En este caso, la red neuronal de una capa oculta resulta mejor en las cinco variables de salida. No obstante, debido a que la diferencia es muy pequeña se puede seleccionar la máquina de soporte vectorial debido a que se observó de forma empírica que su proceso de entrenamiento tomó menos tiempo.

4.4.3 Transformación de señales EEG-MI

En este subapartado se expone la manipulación de señales por medio de la transformada rápida de Fourier (FFT) descrito en el apartado 2.13.1, además, de analizar el desempeño de un modelo de máquina de soporte vectorial (SVM) al ser

entrenada con cuatro conjuntos de datos que representan la señal EEG de la intención de movimiento de abrir y cerrar la mano. El primer conjunto de datos contiene la señal en crudo, el segundo contiene los datos tratados por medio de una normalización Z-score; por su parte, el tercer conjunto de datos contiene la señal cruda procesada por la FFT; y finalmente, un cuarto conjunto transformado por FFT y normalizado con Z-score.

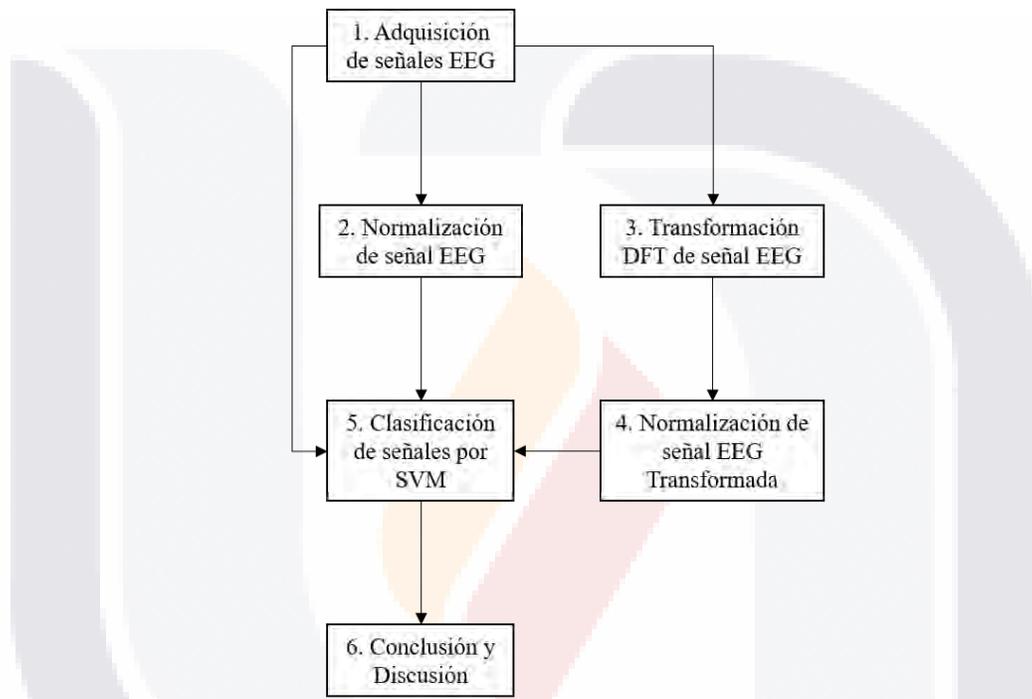


Figura 54. Tratamiento de señales y análisis de desempeño de SVM. Publicado en Anexo A.5.

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. Para la realización de este experimento se realizaron los pasos descritos en el diagrama de la Figura 54.

El primer paso fue la adquisición de señales EEG en crudo. Al igual que en el caso anterior, el estudio se realizó con el conjunto de datos preliminar de la sección 4.2.4 por medio del dispositivo 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 [313], de acceso libre, que permitió el registro de las señales de intención de movimiento correspondientes a abrir y cerrar la mano derecha en archivos csv para su tratamiento posterior.

En este caso, el muestreo se realizó siguiendo un protocolo de captura basado en el presentado por Paredes et al. en [286] y descrito anteriormente en la sección 4.2.3. 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, descrita en el apartado 4.2.2, 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-MI.

El segundo paso fue trasladar una copia de la base de datos cruda a una escala común por medio de la normalización Z-score debido a la magnitud de los valores que toma cada vector de las 14 canales (ver el segundo cálculo de testores de la sección 4.3.3).

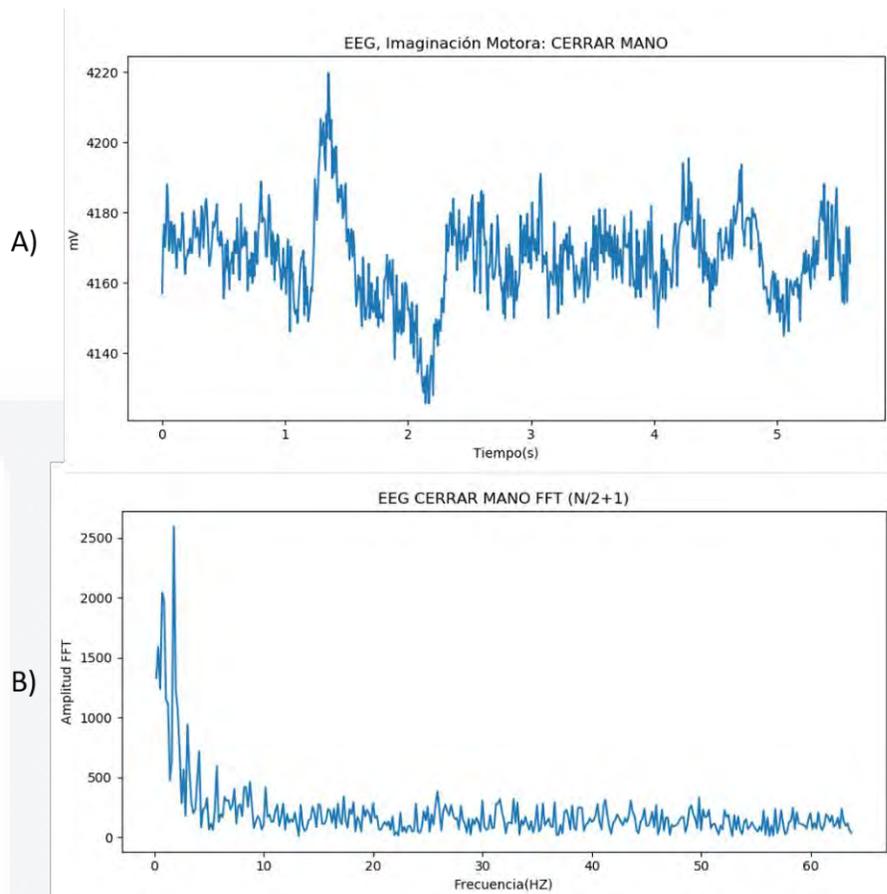


Figura 55. (A) Señal en crudo. (B) Señal transformada por FFT. Publicado en Anexo A.5

De manera paralela, se aplicó una transformada discreta de Fourier como tercer paso, descrita en el apartado 2.13.1. En la Figura 55 se expone la gráfica de la señal en crudo del canal AF3 (gráfica A) correspondiente a la intención 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 de la transformación.

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 Figura 54.

En este punto, se cuenta con cuatro conjuntos de datos:

- Las señales en crudo,

- Las señales en crudo normalizadas,
- Las señales transformadas a Fourier y
- Las señales transformadas normalizadas.

Estos 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 (ver sección 2.11.1): 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 [342].

Tabla 25. Parámetros del modelo SVM. Publicado en Anexo A.5.

Kernel	Gamma	C
rbf	0.04	200

La Tabla 25, 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 el apartado 4.4.2.

Cada modelo de SVM 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 (ver sección 2.10.1). Como medidas de desempeño se utilizaron las métricas de exactitud, precisión, sensibilidad, especificidad y puntuación F1.

En la Figura 56 se muestra el comportamiento de la métrica de exactitud que presentaron los modelos de SVM. Los datos en crudo y los datos tratados con transformada rápida 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 (Fourier)-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 intención de “abrir” como de “cerrar” la mano.

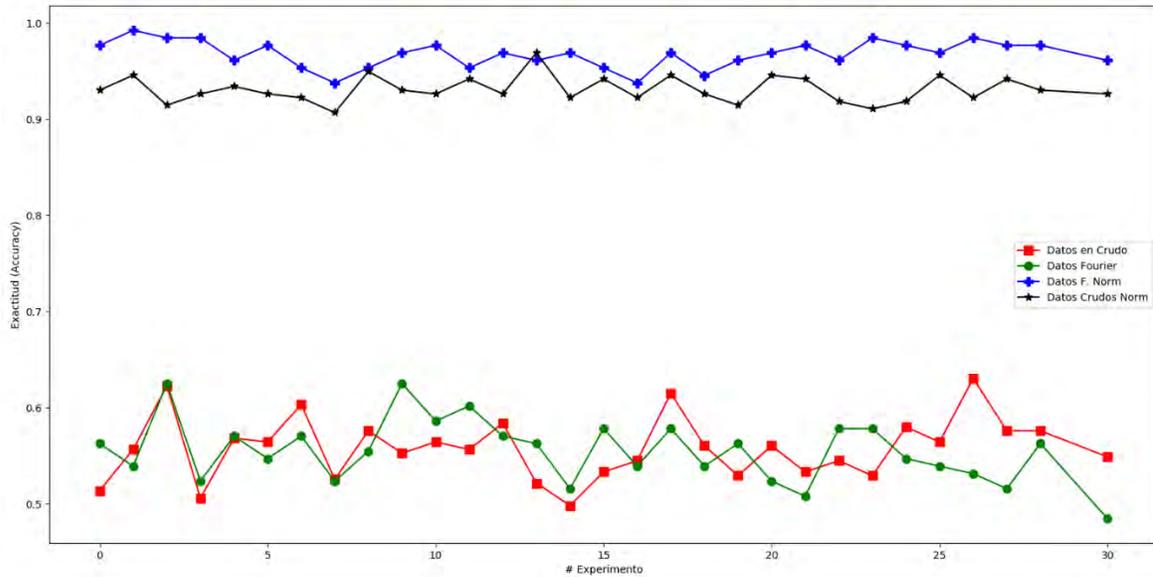


Figura 56. Exactitud (Modelos SVM). Publicado en Anexo A.5.

La métrica siguiente es la precisión que mide la proporción de señales correspondientes a “abrir la mano” que fueron correctamente clasificadas. Como se puede observar en la Figura 56, el comportamiento es similar al de la Figura 55, mostrando que los datos normalizados y transformados (Fourier)-normalizados presentan una mejor distinción de la intención de movimiento de abrir la mano.

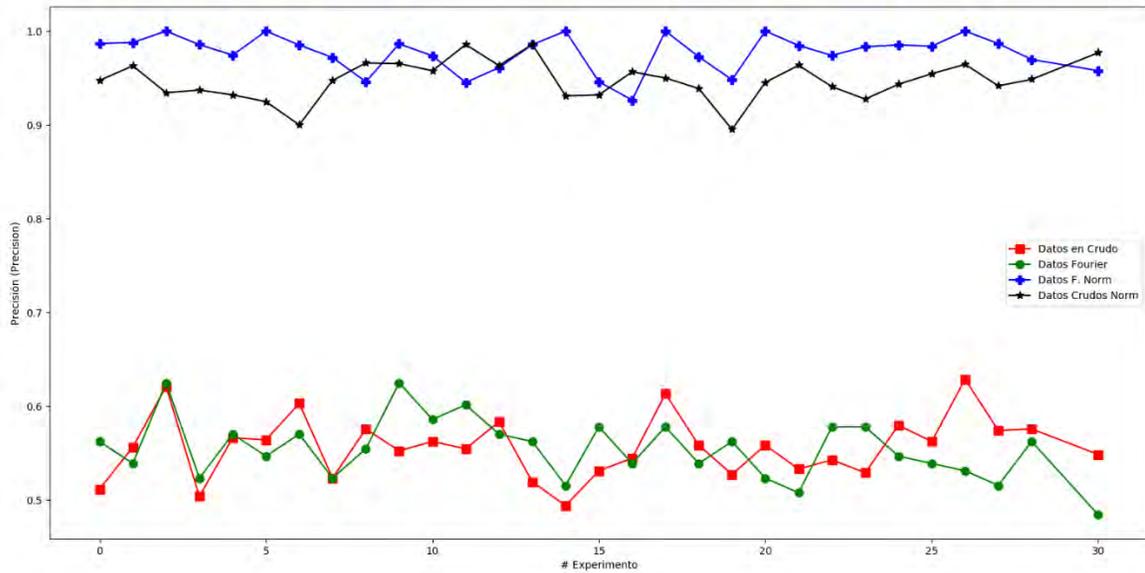


Figura 57. Precisión (Modelo SVM). Publicado en Anexo A.5.

La Figura 58 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 Figura 58 muestra que los modelos que trabajaron con datos crudos y datos transformados son perfectamente capaces de reconocer 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.

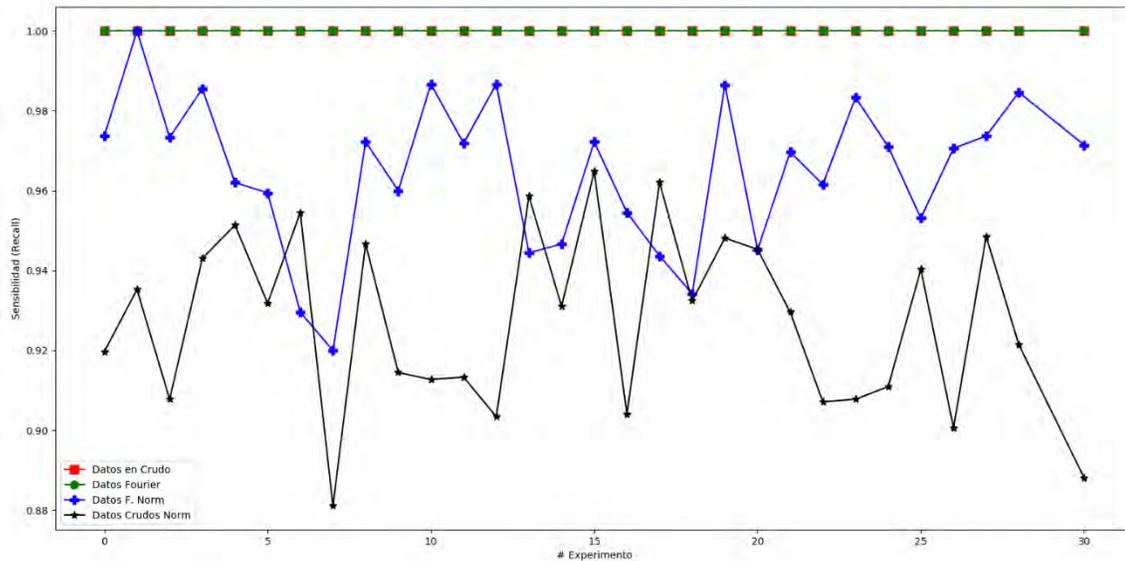


Figura 58. Sensibilidad (Modelo SVM). Publicado en Anexo A.5.

Al igual que en el caso de la exactitud, las réplicas del modelo SVM que trabajaron con el conjunto de datos transformados-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 los modelos con transformada de Fourier son, prácticamente incapaces de identificar una señal con la intención de cerrar la mano (ver Figura 59).

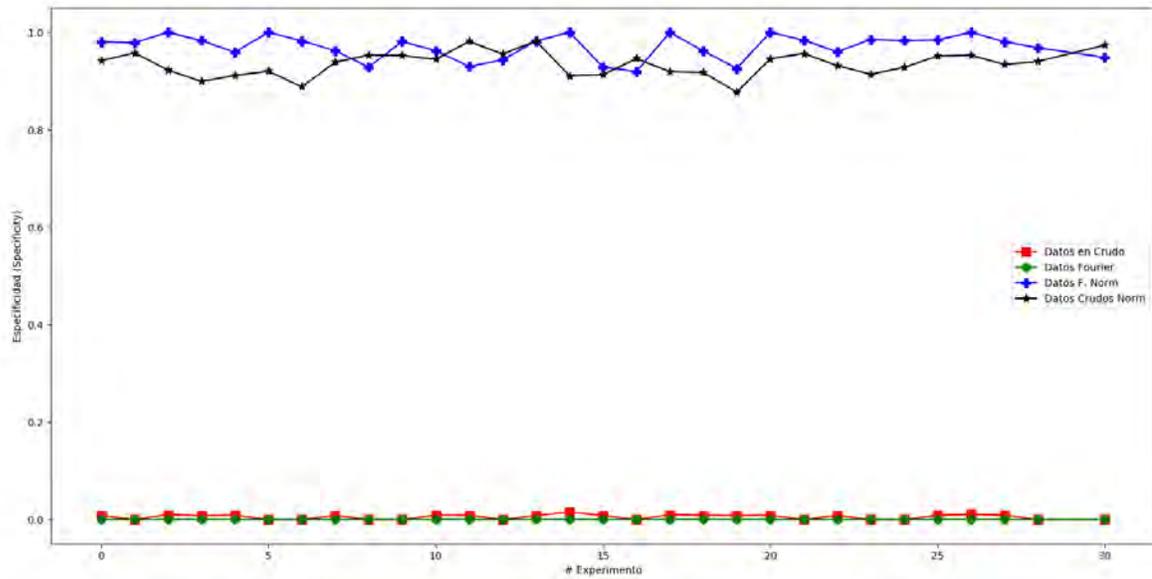


Figura 59. Especificidad (Modelo SVM). Publicado en Anexo A.5.

Sin embargo, los modelos SVM que trabajaron con los conjuntos normalizados y los modelos SVM con conjuntos con transformación (Fourier)-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.

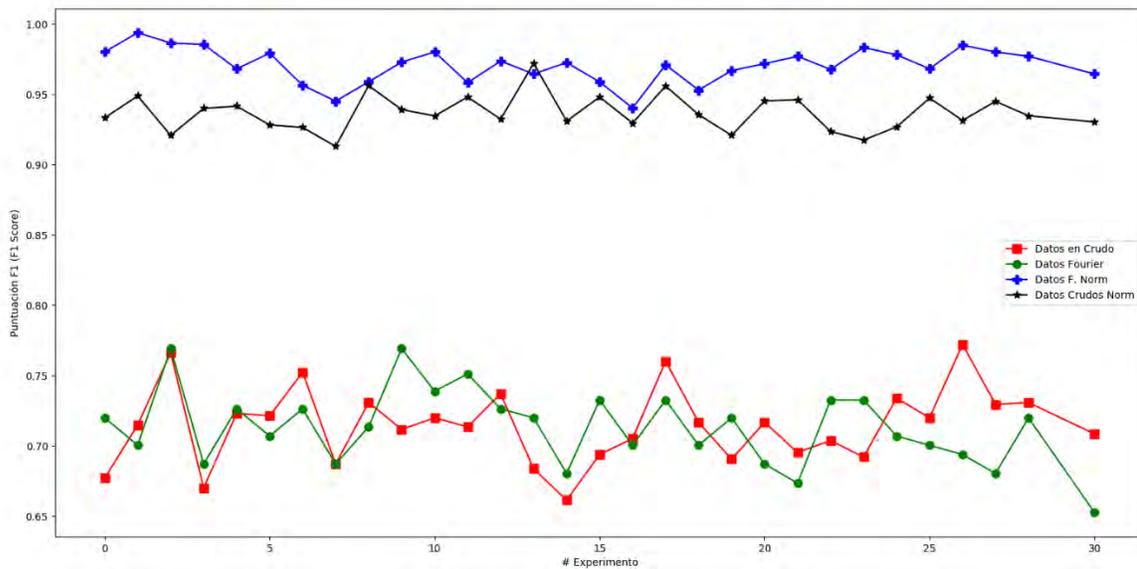


Figura 60. Puntuación F1 (modelo SVM). Publicado en Anexo A.5.

Finalmente, se analiza en la Figura 60 la métrica de la puntuación F1. Aquí se puede observar que, una vez más, los modelos que trabajaron con conjuntos normalizados y los modelos Fourier-normalizados tienen un muy buen nivel de precisión y sensibilidad, siendo superior el modelo con datos transformados y el modelo con datos crudos.

Como se puede observar, la calidad de los datos con los que se alimenta un algoritmo de aprendizaje automático es crucial, 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.

Este análisis fue aceptado para su publicación en la revista Research in Computer Science bajo el título de “Tratamiento de Señales Electroencefalográficas de Imaginación Motora con Fines de Clasificación” y presentado en el congreso COMIA 2021.

4.4.4 Selección de testores típicos por medio de métodos para la toma de decisiones multicriterio

En este apartado se exponen los resultados obtenidos de la implementación del método para la toma de decisiones multicriterio TOPSIS (consultar sección 2.14) aplicado al conjunto de testores típicos encontrados en el segundo cálculo de la sección 4.3.3. Este estudio tuvo como objetivo determinar el testor típico que permitía el mejor desempeño de clasificación en un modelo de red neuronal artificial.

Para realizar el análisis TOPSIS se siguieron los pasos de la Figura 61 los cuales, son descritos a detalle en el apartado 2.14.1.

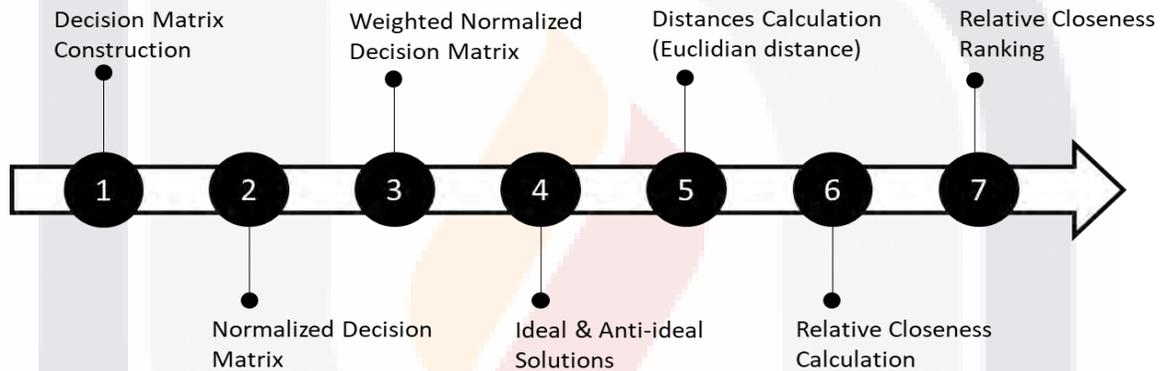


Figura 61. Análisis TOPSIS. Publicado en inglés en Anexo A.8.

Como se puede observar en la Figura 61, el primer paso consistió en la construcción de una matriz de decisión (ver sección 2.11.1). Para ello, se entrenó y validó un modelo de red neuronal artificial (sección 2.12.2) compuesto por dos capas ocultas, cuya configuración se basa en el modelo probado para la clasificación de señales EEG-MI en el apartado 4.4.2 y haciendo uso del repositorio de datos obtenido en el apartado 4.3.1.

Tabla 26. Modelo de red neuronal artificial para análisis TOPSIS. Publicado en Anexo A.8.

Capa de entrada	Capa oculta 1	Función de activación	Capa oculta 2	Función de activación	Capa de salida	Función de activación	Épocas	Batch
14	75	Relu	15	Relu	1	Sigmoid	100	5

El modelo propuesto de red neuronal artificial de la Tabla 26 fue entrenado cinco veces, una vez por cada testor típico de la Tabla 27 (para más información ver sección 4.3.3), con un muestreo aleatorio del 50% de los datos disponibles. Cada entrenamiento del modelo se replicó 30 veces utilizando muestras aleatorias del 25% de la muestra restante que no fue utilizada en la fase de entrenamiento.

Tabla 27. Conjunto de testores típicos de señales EEG-MI (abrir y cerrar mano).
Publicado en Anexo A.8.

Testores Típicos													
AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4
1	1	1	1	1	0	0	0	1	1	1	0	0	1
1	1	1	1	1	1	1	0	0	1	0	0	0	1
1	1	1	1	1	1	0	0	1	1	0	0	0	1
1	1	0	1	1	0	1	0	1	1	1	0	1	1
1	1	0	1	1	0	1	1	1	1	1	0	0	1

Cada réplica se evaluó utilizando las métricas: exactitud, precisión positiva (intención de mano abierta), precisión negativa (intención de mano cerrada), tasa de falsos negativos y tasa de falsos positivos; extraídas de su respectiva matriz de confusión. Al final de cada conjunto de réplicas, los valores de las métricas se promediaron para construir la matriz de decisión de la Tabla 28, es decir, el insumo para la aplicación del método TOPSIS para elegir el testor típico con el mejor rendimiento de clasificación.

Tabla 28. Matriz de decisión y vector de pesos. Publicada en Anexo A.8.

ID	Exactitud	Precisión Positiva	Precisión Negativa	Tasa FP	Tasa FN
TT_1	83.5379627	84.0354695	83.0625839	16.9374161	15.9645305
TT_2	82.9173655	87.2011396	78.8755443	21.1244557	12.7988604
TT_3	83.4317343	83.6756158	83.2012539	16.7987461	16.3243842
TT_4	83.4015431	85.0647696	81.8122399	18.1877601	14.9352304
TT_5	82.5785531	83.5208287	81.6811839	18.3188161	16.4791713
Pesos	0.2	0.35	0.35	0.05	0.05

En la Tabla 28 se muestra también, el vector de pesos. Estos valores se eligieron en función de la importancia de cada criterio de decisión (métricas de la matriz de confusión). Es decir, la precisión positiva y la precisión negativa describen si el modelo de red neuronal artificial puede distinguir cada clase de intenciones de movimiento y, por lo tanto, se les asigna un mayor peso.

El segundo puesto corresponde a la métrica de precisión, que describe la relación entre los objetos correctamente clasificados y el número total de objetos clasificados. Sin embargo, puede que no sea una métrica completamente confiable, ya que puede tener un valor alto, pero existe la posibilidad de que el clasificador solo identifique una clase e ignore el resto. Por lo tanto, se le da un peso menor. Finalmente, para las tasas falso-negativo y falso-positivo, se decidió darles un peso menor debido a que poseen un significado opuesto a las precisiones positiva y negativa. Es decir, si los valores de precisión positiva y negativa aumentan, los valores de las tasas de falsos-positivos y falsos-negativos disminuyen.

Los resultados obtenidos en cada paso del análisis TOPSIS de la Figura 61 se describen a continuación:

- **Paso 2:** Normalización de la matriz de decisión.

Tabla 29. Matriz de decisión normalizada. Publicada en Anexo A.8.

ID	Exactitud	Precisión Positiva	Precisión Negativa	Tasa FP	Tasa FN
TT_1	0.44916928	0.44364985	0.45444211	0.41302293	0.46478745
TT_2	0.44583243	0.46036243	0.43153448	0.51512489	0.3726229
TT_3	0.44859811	0.44175007	0.45520078	0.40964143	0.47526414
TT_4	0.44843577	0.44908385	0.44760137	0.44351286	0.43482066
TT_5	0.4440107	0.4409329	0.44688436	0.4467087	0.47977057

- **Paso 3:** Obtención de la matriz normalizada ponderada.

Tabla 30. Matriz de decisión ponderada. Publicada en Anexo A.8.

ID	Exactitud	Precisión Positiva	Precisión Negativa	Tasa FP	Tasa FN
TT_1	0.08983386	0.15527745	0.15905474	0.02065115	0.02323937
TT_2	0.08916649	0.16112685	0.15103707	0.02575624	0.01863115
TT_3	0.08971962	0.15461252	0.15932027	0.02048207	0.02376321
TT_4	0.08968716	0.15717935	0.15666048	0.02217564	0.02174103
TT_5	0.08880214	0.15432651	0.15640952	0.02233544	0.02398853

- **Paso 4:** Creación de la solución ideal y la solución no-ideal.

Tabla 31. Solución ideal y solución no-ideal. Publicada en Anexo A.8.

Solución	Exactitud	Precisión Positiva	Precisión Negativa	Tasa FP	Tasa FN
A+	0.08983386	0.16112685	0.15932027	0.02048207	0.01863115
A-	0.08880214	0.15432651	0.15103707	0.02575624	0.02398853

Es importante mencionar que para establecer los valores de la solución ideal A^+ , las métricas de exactitud, precisión positiva y precisión negativa tuvieron un sentido positivo, es decir, se eligieron los valores más altos. Mientras que las métricas de tasa de falsos positivos y tasa de falsos negativos tenían un sentido negativo, es decir, se eligieron los valores mínimos. Para la solución no-ideal A^- , se siguió la lógica opuesta.

- **Paso 5:** Obtención de las distancias a la *solución ideal* y a la *solución no-ideal*.

Tabla 32. Distancias a la solución ideal y a la solución no-ideal. Publicada en Anexo A.8.

ID	D+	D-
TT_1	0.00745321	0.00963717
TT_2	0.00984245	0.00866481
TT_3	0.00829383	0.00986928
TT_4	0.00593451	0.00764308
TT_5	0.00937646	0.00636909

- **Paso 6:** Obtención de la cercanía relativa.

Tabla 33. Cercanías relativas. Publicada en Anexo A.8.

ID	D_j
TT_1	0.56389437
TT_2	0.46818427
TT_3	0.54336975
TT_4	0.56291884
TT_5	0.40450083

Al ordenar el conjunto de testores típicos en orden descendente de acuerdo con los valores de cercanía relativa obtenidos en la Tabla 33, se puede conocer el mejor y el peor testor típico como se muestra en la Tabla 34.

Tabla 34. Resultados TOPSIS (Ranking de alternativas). Publicado en Anexo A.8.

Ranking	Exactitud	Precisión Positiva	Precisión Negativa	Tasa FP	Tasa FN	Exactitud	Precisión Positiva
1	TT_1	9	83.537962	84.035469	83.062583	16.937416	15.964530
2	TT_4	10	83.401543	85.064769	81.812239	18.187760	14.935230
3	TT_3	9	83.431734	83.675615	83.201253	16.798746	16.324384
4	TT_2	9	82.917365	87.201139	78.875544	21.124455	12.798860
5	TT_5	10	82.578553	83.520828	81.681183	18.318816	16.479171

Como se puede observar, el testor típico 1 es quien muestra un mejor desempeño en la clasificación de intención de movimiento. Es importante mencionar que el mejor testor típico se compone del menor número de características, por lo que se alinea al objetivo de la selección de subconjuntos de características presentado en

la sección 2.6, manteniendo una buena capacidad para discernir entre las clases involucradas de intención de movimiento.

Además, se muestra la facilidad de implementar el método TOPSIS para la toma de decisiones multicriterio con pocos parámetros, pero mostrando una capacidad robusta al trabajar tanto con criterios cuantitativos como cualitativos.

Los resultados presentados en esta sección fueron aceptados para su publicación como capítulo del libro “Innovation and Competitiveness in Industry 4.0 Based on Intelligent Systems” de Springer, bajo el título “Feature Selection in Electroencephalographic Signals Using a Multicriteria Decision Analysis Method”. Para más información, consultar el Anexo A.8.

4.5 Fase 5

Como se expuso en la Figura 39 de la metodología expuesta en la sección 3, la Fase 5 comprende la integración del trabajo realizado en las fases previas de la propuesta metodológica. En otras palabras, es integra propiamente un mecanismo híbrido de clasificación descrito por la Figura 62 denominado MHH-FSS-RNA. La representación del modelo propuesto toma como base el modelo de reconocimiento de patrones para clasificación descrito en la sección 2.6.

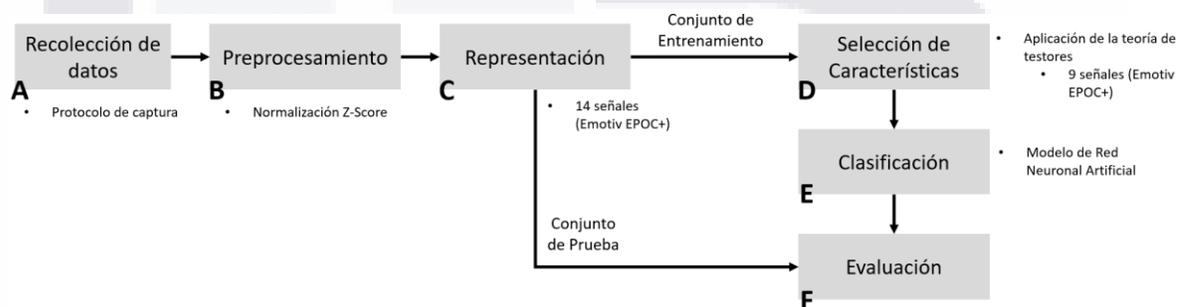


Figura 62. Modelo híbrido de clasificación.

El MHH-FSS-RNA integra los elementos primordiales que fueron estudiados, analizados, desarrollados e implementados a lo largo de este reporte de tesis:

- Protocolo de captura de señales EEG-MI
- La selección de un método de preprocesamiento de señales EEG-MI
- El uso de un repositorio de datos que obedece al testor típico con mejor desempeño de clasificación determinado por el método TOPSIS.
- La implementación de un modelo de clasificación clásico.
- Evaluación del modelo.

En las subsecciones siguientes se describe con mayor detalle cada uno de los elementos que componen el modelo híbrido de clasificación, MHH-FSS-RNA.

4.5.1 Selección de protocolo de captura

El dispositivo Emotiv EPOC+ permitió la captura de señales EEG-MI. Sin embargo, debido a la naturaleza de las señales EEG se optó por seguir un protocolo de captura que permitió la réplica estandarizada en cada uno de los sujetos de prueba.



Figura 63. Protocolo de captura de señales EEG-MI aplicado en el modelo MHH-FSS-RNA.

El protocolo de captura utilizado para la integración del modelo de clasificación híbrido fue el expuesto en la Figura 63 creado con el apoyo del alumno de maestría Carlos Martínez. Quién después de una serie de muestreos se pudo afinar el proceso. De esta manera se logró crear un modelo de muestreo de quince segundos, de los cuales los primeros cinco permiten que el sujeto de prueba se prepare y evoqué con mayor concentración la intención de movimiento que se le indique. Cuenta, además, de diez segundos de muestro en los que se registran propiamente las señales con la intención de movimiento. Finalmente, cuenta con cinco segundos más para el descanso del sujeto de prueba. Para más información, el lector puede consultar la sección 4.2.3.

4.5.2 Selección de método de preprocesamiento

Como se ha mencionado anteriormente, el objetivo del preprocesamiento es facilitar el análisis de la información. En este caso, como se expuso en la sección 4.3.2, se estudió el comportamiento de las señales EEG-MI. Como resultado, se encontró que a pesar de cada uno de los canales utiliza el mismo tipo variable (μV), los

catorce canales del dispositivo (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4) muestran gran dispersión en sus desviaciones estándar. Además, por medio de un estudio de correlaciones de Pearson, se encontró la existencia de una correlación positiva entre las catorce variables. En la misma sección, se concluye en aplicar normalización de los datos.

Sin embargo, en la sección 4.4.3 se realizó un estudio para comparar la influencia de métodos de preprocesamiento como, precisamente, la normalización, así como la transformada rápida de Fourier y su combinación en un modelo de máquina de soporte vectorial. Como se recordará, aplicar únicamente transformada de Fourier no tuvo un gran beneficio en el desempeño de la clasificación de registros de señales EEG-MI. En cambio, utilizar normalización e incluso combinarse con la transformada de Fourier tiene un mayor impacto en la clasificación, permitiendo un modelo con gran exactitud y un buen desempeño en la distinción de ambas clases (abrir y cerrar la mano derecha).

Sin embargo, debido a que se busca un modelo con un menor uso de recursos computacionales, se decidió optar por utilizar solo la normalización Z-score dada por la ecuación 45. Esto, dado el hecho de que no hay diferencia estadística significativa en el desempeño del modelo de máquina de soporte vectorial al utilizar solo normalización y utilizar la combinación de normalización y transformada de Fourier (consultar estudio completo en la sección 4.4.3).

$$new\ value = \frac{X - \mu}{\sigma} \quad (45)$$

4.5.3 Representación de datos

Los conjuntos de datos describen señales EEG-MI de abrir y cerrar la mano derecha en función de los catorce electrodos que componen el dispositivo Emotiv EPOC+ dispositivo (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4). Como se describe en las secciones 4.1 y 4.2.1, los electrodos del dispositivo Emotiv se colocan obedeciendo el sistema estándar 10-20. Donde cada uno de ellos permite el registro de la señal en micro Volts (μV) cuyo análisis de comportamiento se expone en la sección 4.3.2.

Sin embargo, los datos fueron preprocesados para su uso dentro del modelo de clasificación propuesto. Por lo tanto, su representación está dada por los valores obtenidos a partir del proceso de normalización seleccionado.

4.5.4 Selección de subconjuntos de características

Para este proceso se trabajó con la aplicación de la teoría de testores, como parte de la selección de subconjuntos de características del reconocimiento de patrones. Tal como se describe en el apartado 4.3.3, se encontró un conjunto de cinco testores típicos, los cuales, representan subconjuntos mínimos de características necesarios para distinguir objetos pertenecientes a diferentes clases.

Tabla 35. Testor típico seleccionado por TOPSIS.

Testor Típico													
AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4
1	1	1	1	1	0	0	0	1	1	1	0	0	1

Sin embargo, como se pudo apreciar, cada testor típico posee un desempeño de clasificación diferente. Por ello, gracias al método de toma de decisiones multicriterio, TOPSIS, fue posible conocer aquel testor típico con mejor desempeño en un proceso de clasificación utilizando un modelo de red neuronal artificial estudiado en la sección 4.4.2. En este caso, el testor típico seleccionado es el

expuesto en la Tabla 35. El estudio TOPSIS se puede consultar a detalle en el apartado 4.4.4.

4.5.5 Diseño y evaluación de la red neuronal artificial

Hasta este punto, se cuenta con un protocolo de captura de datos EEG-MI, un método de preprocesamiento de datos y un subconjunto de características (testor típico) seleccionados de manera formal. El siguiente elemento del modelo de clasificación híbrido es, propiamente, seleccionar un modelo de clasificación.

La selección del modelo de clasificación se hizo con base en la afinación de parámetros expuesta en la sección 4.4.2. En este caso, el modelo que mejor desempeño tuvo en la clasificación de señales EEG-MI fue el de red neuronal artificial con dos capas ocultas el cual, se muestra en Tabla 36.

Tabla 36. Modelo de red neuronal artificial para modelo MHH-FSS-RNA.

Capa de entrada	Capa oculta 1	Función de activación	Capa oculta 2	Función de activación	Capa de salida	Función de activación	Épocas	Batch
14	75	Relu	15	Relu	1	Sigmoid	200	10

Sin embargo, el estudio realizado contempla el uso del conjunto de características completo, es decir, los catorce electrodos disponibles. Es por ello, que se realizó un nuevo ajuste al modelo seleccionado. De igual manera, se hizo uso de la regla de la pirámide geométrica para la aproximación del número de neuronas ocultas en una red neuronal. La regla establece que el número de neuronas en las capas ocultas debe presentar una disminución, es decir, el número de neuronas de entrada deber ser menor al número de neuronas de salida [343].

Una red neuronal requiere de más recursos computacionales por cada capa de es añadida a la red neuronal. Es por ello por lo que es recomendable que en problemas pequeños no se agreguen más de dos capas ocultas [344]. Para definir el número de neuronas en un modelo de red neuronal artificial de dos capas se tomó como base las ecuaciones 46 a 48.

$$h1 = o * r^2 \tag{46}$$

$$h2 = o * r \tag{47}$$

$$r = \sqrt[3]{i/o} \tag{48}$$

Donde el valor $h1$ de la ecuación 46, representa el número de neuronas en la primera capa oculta; $h2$ (ecuación 47), es el número de neuronas en la segunda capa oculta; i , es el número de neuronas de entrada; y, finalmente, o representa el número de neuronas de salida. Cabe recalcar que las ecuaciones presentadas son aproximaciones, por lo que representan una base sólida en el diseño de redes neuronales iniciando con modelos lo más sencillos posibles [344].

Para este estudio se tomó un valor $i = 9$, obedeciendo al número de características consideradas por el testor típico seleccionado de la Tabla 36. También, se partió de un valor $o = 1$, pues al ser una decisión dicotómica, es suficiente con una única neurona de salida.

Tabla 37. Modelos de clasificación

Modelo	Configuración		Desempeño	
1	Entrada	$i = 9$	E	0.855
	Salida, activación	$o = 1, sigmoid$	TPR	0.8125
	Capa 1, activación	$h1 = 75, relu$	TNR	0.8960
	Capa 2, activación	$h2 = 15, relu$	FPR	0.1039
	Épocas	$e = 100$	FNR	0.1875
	Lote	$batch = 5$		
2	Entrada	$i = 9$	E	0.8527
	Salida, activación	$o = 1, sigmoid$	TPR	0.8930
	Capa 1, activación	$h1 = 75, relu$	TNR	0.8164
	Capa 2, activación	$h2 = 30, softmax$	FPR	0.1835
	Épocas	$e = 100$	FNR	0.1069
	Lote	$batch = 5$		
3	Entrada	$i = 9$	E	0.8554
	Salida, activación	$o = 1, sigmoid$	TPR	0.8806
	Capa 1, activación	$h1 = 75, relu$	TNR	0.8290

	Capa 2, activación	$h2 = 30, relu$	FPR	0.1709
	Épocas	$e = 100$	FNR	0.1194
	Lote	$batch = 5$		
4	Entrada	$i = 9$	E	0.8324
	Salida, activación	$o = 1, sigmoid$	TPR	0.8020
	Capa 1, activación	$h1 = 5, relu$	TNR	0.8613
	Capa 2, activación	$h2 = 2, relu$	FPR	0.1386
	Épocas	$e = 100$	FNR	0.1979
	Lote	$batch = 5$		
5	Entrada	$i = 9$	E	0.7944
	Salida, activación	$o = 1, sigmoid$	TPR	0.7807
	Capa 1, activación	$h1 = 5, relu$	TNR	0.8067
	Capa 2, activación	$h2 = 2, relu$	FPR	0.1932
	Épocas	$e = 200$	FNR	0.2192
	Lote	$batch = 10$		
6	Entrada	$i = 9$	E	0.8426
	Salida, activación	$o = 1, sigmoid$	TPR	0.8128
	Capa 1, activación	$h1 = 10, relu$	TNR	0.8695
	Capa 2, activación	$h2 = 4, relu$	FPR	0.1304
	Épocas	$e = 200$	FNR	0.1871
	Lote	$batch = 10$		
7	Entrada	$i = 9$	E	0.8401
	Salida, activación	$o = 1, sigmoid$	TPR	0.8567
	Capa 1, activación	$h1 = 30, relu$	TNR	0.8248
	Capa 2, activación	$h2 = 12, relu$	FPR	0.1751
	Épocas	$e = 200$	FNR	0.1412
	Lote	$batch = 10$		

En la Tabla 37, se pueden observar distintas configuraciones de parámetros para el ajuste del modelo de red neuronal con las características que indica el testor típico de la sección 4.5.3, así como las métricas obtenidas a partir de una matriz de confusión. Cabe recordar, que se siguió la nomenclatura de sklearn para la obtención de la matriz y el cálculo de las métricas. De esta manera, los registros EEG-IM de cerrar la mano corresponden a casos positivos, es decir, fueron

etiquetados con un valor de 1. Por tanto, los registros EEG-MI de abrir mano corresponden a casos negativos, por lo que fueron etiquetados con valor de 0.

Los modelos 1, 2, 3 se basan en el modelo original de la Tabla 36 el cual, como se recordará, resultó como mejor modelo en clasificación del conjunto completo de características. De manera empírica se puede advertir la no existencia de diferencias significativas en los parámetros de salida. Pues, se puede observar una media aproximada de 0.8543, es decir, un 85.43% de exactitud. Sin embargo, tomando en cuenta estos tres modelos, se puede resaltar que los modelos 2 y 3 poseen una mejor respuesta para distinguir señales EEG-MI de cerrar la mano, con un 0.8930 y 0.88 en la métrica de TPR (True positive rate). Por el contrario, el modelo 1 se distingue por poseer mejor capacidad de detección de registros con intención de abrir la mano (casos negativos). Por su parte, el modelo 2 fue configurado con la función de activación softmax lo que no benefició en la minimización en la tasa de falsos positivos, ni en la maximización de la exactitud y la tasa de verdaderos negativos (métrica TNR, para señales de abrir mano).

A pesar de que los tres primeros modelos poseen una exactitud aceptable, al igual que sus tasas positivas y negativas, se puede pensar en que los modelos pueden resultar robustos y, por tanto, con mayor requerimiento computacional. Es por ello por lo que se construyeron cuatro modelos nuevos, cuya configuración toma como punto de partida las ecuaciones 46, 47 y 48.

Como se puede observar, el modelo 4 se tomó como inicio al correr con los parámetros obtenidos por las ecuaciones. En este caso, y desde un punto de vista empírico, sus métricas de desempeño son muy similares a los obtenidos por los modelos anteriores. Manteniendo, además, un equilibrio entre la distinción de señales de abrir mano (TNR) y las señales de cerrar mano (TPR). Todo con la ventaja de requerir menos recursos al poseer menos cantidad de neuronas artificiales por capa oculta.

Para el caso del modelo 5, se decidió experimentar con el valor del número de épocas y del tamaño del lote. Sin embargo, a pesar de mejorar dichos valores, el desempeño en todas las métricas descendió considerablemente.

En los modelos 6 y 7 se incrementó el número de neuronas en sus dos capas ocultas. Como se puede observar, el desempeño mejoró con respecto al modelo 5. No obstante, se puede observar que el aumento en la robustez de los modelos no provoca cambios determinantes.

Para concluir este apartado, se toma la decisión de elegir el modelo 6, como el modelo más adecuado para la clasificación de señales EEG-MI de abrir y cerrar la mano derecha, descritos por testores típicos. El modelo 6 posee la particularidad de ser el más equilibrado, pues se conforma con un menor número de neuronas en sus capas ocultas y, por tanto, menores requerimientos computacionales. Todo ello, con un buen desempeño de clasificación. Es así como el mecanismo MHH-FSS-RNA es compuesto por una red neuronal artificial de dos capas que corre bajo los parámetros del modelo 6, expuesto en la Tabla 37.

4.6 Fase 6

La Fase 6 de la propuesta metodológica comprende la aplicación del mecanismo MHH-FSS-RNA en la clasificación de señales EEG-MI. La aplicación consistió en el control de un dispositivo externo, en este caso, se trató de un brazo mecánico expuesto en la Figura 64. Todo ello a través de la clasificación de un nuevo repositorio de señales con intención de movimiento (abrir y cerrar mano derecha).



Figura 64. Brazo mecánico para la etapa de prueba de la Fase 6.

Es importante mencionar que el repositorio con el cual, se entrenó y validó el mecanismo MHH-FSS-RNA en el apartado 4.5, proviene del mismo sujeto de prueba de quien se muestro el repositorio para la Fase 6. Ambos repositorios se obtuvieron en una única sesión de muestro para asegurar que ambos compartieran exactamente las mismas condiciones ambientales. Pues como se menciona en el

apartado 2.5, los sistemas BCI son ajustados de manera individual debido a la naturaleza altamente variable de las señales EEG. De esta manera, se debe tomar en cuenta que para probar el mecanismo MHH-FSS-RNA con un nuevo sujeto de prueba, el mecanismo deberá ser entrenado de nuevo antes de ponerse a prueba con la aplicación de la Fase 6. El repositorio en cuestión se compone de 1956 registros, de los cuales, 1072 corresponden a la intención de abrir la mano y, 884 registros de la intención de cerrar la mano derecha.

Como paso previo a la clasificación de los registros EEG-MI, la base de datos fue sometida a un proceso de normalización. Esto, con el objetivo que los datos sean reconocibles por el mecanismo MHH-FSS-RNA, recordando que los datos con los que se entrenó y validó fueron preprocesados de la misma manera.

En este mismo sentido, el repositorio fue reducido en cuanto el número de características que lo describen, obedeciendo al testor típico con los canales AF3, F7, F3, FC5, T7, P8, T8, FC6, AF4, con los que fue entrenado y validado el mecanismo MHH-FSS-RNA de clasificación en la Fase 5.

El brazo mecánico de la Figura 64 es el modelo V3 del proveedor Biomakers construida con tecnología de impresión 3D compuesta de un microcontrolador ATmega328P, cinco servos mg90, una placa NANO, batería y cargador. Para la configuración del brazo, se hizo uso del IDE de Arduino en su versión 1.8.19.

El código utilizado para el control interno del brazo mecánico se expone en la en la Figura 65. Dicho código consiste en la declaración de cada uno de los dedos, uno por cada servo motor y su alineación inicial. Para generar el movimiento, el dispositivo se encuentra a la espera del comando por parte del mecanismo MHH-FSS-RNA, el cual, está cargado en Python. Es decir, el mecanismo lee una señal del repositorio y la clasifica para después, según el resultante, envíe la intención detectada al brazo mecánico a través de una conexión alámbrica USB. En este caso, el brazo recibe un valor de 1, que indica la apertura de la mano; y un valor de 2 que indica el cierre.

```

#include <Servo.h>
Servo pulgar; //Dedo pulgar
Servo menique; //Dedo menique
Servo indice; //Dedo indice
Servo medio; //Dedo medio
Servo anular; //Dedo anular

int ti = 3; //tiempo de intervalo, movimiento angular de cada grado del servomotor
int tp =100; //intervalo de tiempo entre un dedo y otro
void setup() {
  // put your setup code here, to run once:
  Serial.begin(9600); //Cominación serial

  //Alta de cada dedo
  pulgar.attach(3);
  indice.attach(4);
  medio.attach(5);
  anular.attach(7);
  menique.attach(2);

  //Posiciones Iniciales, Dedos alineados en mano abierta
  pulgar.write(170); //170 - 10
  indice.write(170); //170 - 50
  medio.write(170); //170 - 50
  anular.write(170); //170 - 50
  menique.write(170); //170 - 50
}

void loop() {
  // put your main code here, to run repeatedly:
  char p='a'; //estado de la mano, a-abierta | c-cerrada
  if(Serial.available()>0){
    char option = Serial.read(); //1 - señal de abrir, 2 - señal de cerrar
    if(p=='a' && option=='2'){
      for(int x=170; x>10; x--){ //Cerrar pulgar
        pulgar.write(x);
        //delay(ti);
      }
      for(int x = 170; x > 60; x--){
        indice.write(x);
        medio.write(x);
        anular.write(x);
        menique.write(x);
        delay(ti);
      }
      p='b';
      delay(tp);
    }

    if(p=='b' && option=='1'){
      for(int x=10; x<170; x++){
        pulgar.write(x);
        //delay(ti);
      }
      for(int x=60; x<170; x++){
        indice.write(x);
        medio.write(x);
        anular.write(x);
        menique.write(x);
        delay(ti);
      }
      p='a';
      delay(tp);
    }
  }
}

```

Figura 65. Código para para la placa Arduino del brazo mecánico.

Al someter el nuevo repositorio al mecanismo MHH-FSS-RNA para su clasificación se reporta una exactitud del 51.687%. Con una precisión positiva, es decir, el reconocimiento de la intención de cerrar la mano, con un valor del 47.96%. Mientras que, se tiene una precisión negativa, el reconocimiento de abrir la mano, del 54.75%. Debido al desempeño obtenido por el mecanismo MHH-FSS-RNA en la clasificación de nuevas señales EEG-MI se procederá, como trabajo a futuro, con un comportamiento de histéresis para mejorar la precisión obtenida.

El término de histéresis es empleado para describir el comportamiento en el cual pueden existir varios estados estables para valores dados de los parámetros de control. Además, estos estados pueden ocurrir dada una variación lenta de estos parámetros [345], [346]. De manera formal, la histéresis se define como *“la tendencia de un material a conservar una de sus propiedades, en ausencia del estímulo que la ha generado”* [347]. Cuya aplicación abarca una amplia variedad de fenómenos desde electrónicos hasta los económicos.

4.7 Productos

4.7.1 Publicaciones

1. E. Gallegos Acosta, M. D. Torres Soto, F. J. Álvarez Rodríguez, and A. Torres Soto, “Integración del operador de alteración a metaheurísticas evolutivas para la aplicación de la teoría de testores en patologías médicas,” DYNA NEW Technol., vol. 6, no. 1, p. [12 p.]-[12 p.], 2019. (Anexo A.1)
2. E. Gallegos Acosta, M. D. Torres Soto, F. J. Álvarez Rodríguez, and A. Torres Soto, “Clasificación de señales electroencefalográficas por medio de un clasificador bayesiano”. Memorias del Congreso Investigación en el Posgrado, 2019. Universidad Autónoma de Aguascalientes. (Anexo A.2)
3. E. Gallegos Acosta, M. D. Torres Soto, F. J. Álvarez Rodríguez, and A. Torres Soto, “Manipulación de metaheurísticas para la búsqueda de testores típicos” DYNA, DOI: <http://dx.doi.org/10.6036/9375> (Anexo A.3)
4. A. E. Gallegos Acosta, M. D. Torres Soto, A. Torres Soto, and E. E. Ponce de León Sentí, “Contrastación de algoritmos de aprendizaje automático para la clasificación de señales EEG”. Research in Computer Science, vol. 149, no. 8, pp. 515-525, 2020. (Anexo A.4)
5. A. E. Gallegos Acosta, M. D. Torres Soto, A. Torres Soto, and E. E. Ponce de León Sentí, “Tratamiento de señales electroencefalográficas de imaginación motora con fines de clasificación”, Research in Computer Science, COMIA 2021. (En proceso de publicación). (Anexo A.5)
6. A. E. Gallegos Acosta, M. D. Torres Soto, A. Torres Soto, and E. E. Ponce de León Sentí, “Procesamiento y clasificación de señales

electroencefalográficas con imaginación motora”. Memorias del Congreso Investigación en el Posgrado, 2021. Universidad Autónoma de Aguascalientes. (Anexo A.6)

7. A. E. Gallegos Acosta, M. D. Torres Soto, A. Torres Soto, and E. E. Ponce de León Sentí, “Feature subset selection in electroencephalographic signals using typical testors”. Research in Computer Science, MICAI 2021. (En proceso de publicación). (Anexo A.7)
8. A. E. Gallegos Acosta, M. D. Torres Soto, A. Torres Soto, E. E. Ponce de León Sentí, and C. A. Ochoa Ruíz Zezzatti, “*Feature selection in electroencephalographic signals using a multicriteria decision analysis method*”. Innovation and Competitiveness in Industry 4.0 Based on Intelligent Systems, Springer. (En proceso de publicación). (Anexo A.8)
9. A. E. Gallegos Acosta, M. D. Torres Soto, A. Torres Soto, and E. E. Ponce de León Sentí, “Toma de decisiones en testores típicos de señales EEG con intención de movimiento”. Memorias del Congreso Investigación en el Posgrado, 2022. (Anexo A.9)

4.7.2 Asesorías

1	Proyecto:	“Adquisición, procesamiento y clasificación de señales de electroencefalografía para intención de movimientos con Redes Neuronales”.
	Autor(a):	Ramírez Ruíz Esparza, Laura Karina.
	Dirección:	María Dolores Torres Soto, Aurora Torres Soto.
	Comité Tutoral:	Alexis Edmundo Gallegos Acosta, Francisco Javier Álvarez Rodríguez.
	Nivel:	Licenciatura
	Estado:	Titulada
2	Proyecto:	“Metaheurística para interpretación de comandos cerebro-computadora”.
	Autor(a):	Martínez Díaz, Carlos Antonio.
	Dirección:	María Dolores Torres Soto, Aurora Torres Soto.
	Comité Tutoral:	Alexis Edmundo Gallegos Acosta.
	Nivel:	Maestría
	Estado:	Titulado
3	Proyecto:	“Clasificador neuronal para la interpretación de señales electroencefalográficas de intención de movimiento”.
	Autor(a):	Mendez Ramos, Fernando Alexis
	Dirección:	Aurora Torres Soto, Alexis Edmundo Gallegos Acosta
	Comité Tutoral:	María Dolores Torres Soto, Francisco Javier Álvarez Rodríguez.
	Nivel:	Licenciatura
	Estado:	Titulado
4	Proyecto:	“”.
	Autor(a):	Joel
	Dirección:	Aurora Torres Soto, María Dolores Torres Soto
	Comité Tutoral:	Alexis Edmundo Gallegos Acosta, Francisco Javier Álvarez Rodríguez.
	Nivel:	Licenciatura
	Estado:	Definición de protocolo de investigación

4.7.3 Eventos

Tipo	Evento
Ponencia	Congreso de Investigación en el Posgrado 2019, Universidad Autónoma de Aguascalientes.
Asistencia	“Escuela de Cómputo Evolutivo” en CIMAT del 21 al 23 de octubre de 2019.
Tallerista	“Introducción al aprendizaje automático por medio de herramientas Google Colab” 9 y 10 de diciembre de 2019, Universidad Autónoma de Aguascalientes.
Ponencia	XII Congreso Mexicano de Inteligencia Artificial 2020, Universidad Autónoma de Ciudad Juárez. 5 al 7 de agosto 2020.
Asistencia	1° Simposio Nacional de Inteligencia Artificial e Industria 4.0, UNIVA.
Asistencia	XIV Congreso de Ciencias Exactas 2020, Universidad Autónoma de Aguascalientes.
Evaluación	Artículo para Revista DYNA TECH, 2020
Ponencia	XIII Congreso Mexicano de Inteligencia Artificial 2021, Universidad de Sonora. 18 al 21 de mayo 2021.
Ponencia	Congreso de Investigación en el Posgrado 2021, Universidad Autónoma de Aguascalientes.
Evaluación	Mesa de Ciencias Exactas e Ingenierías. Congreso Internacional Investigación en el Posgrado 2021, Universidad Autónoma de Aguascalientes.
Ponencia	Mexican International Conference on Artificial Intelligence, MICAI 2021
Asistencia	XV Congreso de Ciencias Exactas 2021, Universidad Autónoma de Aguascalientes.
Asistencia	Congreso Internacional de Inteligencia Artificial e Industria 4.0, UNIVA.
Ponencia	Congreso de Investigación en el Posgrado 2022, Universidad Autónoma de Aguascalientes.
Evaluación	Posters para el Workshop on Hybrid Intelligent Systems, MICAI 2022

4.7.4 Docencia

1	Materia:	“Tópicos Selectos III, Parte 1: Técnicas Heurísticas Bioinspiradas”
	Nivel:	Maestría
	Programa:	Maestría en Ciencias con Opción a Computación y Matemáticas Aplicadas
	Periodo	Agosto – diciembre 2021

Capítulo V

Conclusiones

Este proyecto de tesis tuvo como objetivo la obtención, manipulación e interpretación de señales electroencefalográficas con intención de movimiento. Para ello, se presentó en este documento de tesis el diseño de una propuesta metodológica para el análisis y señales electroencefalográficas con intención de movimiento. A partir de esta metodología se creó el modelo híbrido de clasificación MHH-FSS-RNA que permitiera distinguir de manera automática la intención del usuario. En este caso, centrándose en dos movimientos específicos: abrir y cerrar la mano derecha. Además de poner a prueba el modelo mencionado a través de una aplicación práctica que consistió en el movimiento de un brazo mecánico que obedece a la intención representada por la señal electroencefalográfica.

Al inicio de este documento, se tiene la captura de las señales y la construcción de repositorios. Para este caso, se dispuso del dispositivo Emotiv EPOC+ cuya ventaja más clara es el número de electrodos disponibles respecto de otros dispositivos comerciales. Pues, a diferencia de estos, el EPOC+ permitió la consideración de más zonas de la corteza cerebral. Además de que la colocación de los electrodos disponibles está respaldada por el sistema 10-20, un estándar internacional utilizado para la correcta colocación de electrodos para estudios de electroencefalograma realizados, en su mayoría, bajo contextos médicos. Sin embargo, uno de los principales inconvenientes a destacar sobre el uso del EPOC+ es el costo de las licencias para el uso de sus aplicaciones. Para resolverlo, se tomó la alternativa de utilizar aplicaciones como Cykit y OpenVibe los cuales, a pesar de requerir una configuración especial para el correcto funcionamiento del dispositivo, significó también en una ventaja en el diseño de los protocolos de captura, en el

registro de las señales en archivos csv y en la visualización del comportamiento de las señales.

Es importante mencionar que el muestro de señales electroencefalográficas con intención de movimiento se hizo de un protocolo de captura. Este protocolo fue diseñado debido a que las señales electroencefalográficas son sensibles a los estímulos visuales, auditivos o físicos provenientes del exterior. Además, de que la práctica de intención de movimiento requiere de la plena concentración de los sujetos de prueba. Es por ello, que la definición de un protocolo de captura permitió estandarizar las condiciones de captura, así como el perfil que debe cubrir el sujeto de prueba y las condiciones ambientales necesarias, de manera que se asegura una mejor sesión de muestreo.

Para el segundo objetivo particular, se consideró la aplicación de mecanismos de preprocesamiento a los datos obtenidos. Esto se debe a que las señales EEG representan información compleja y, a su, resulta extraordinariamente sensible a ruido provocado por estímulos en el ambiente y la interferencia del propio cuerpo humano como los tejidos intermedios. De manera que, al final de un muestro de señales es muy fácil observar una alta variabilidad en las señales. Incluso, a pesar de que cada nodo recibe y almacena el mismo tipo de información (μV), se pudo observar una dispersión importante en las desviaciones estándar. Sin embargo, es claro que, al igual que se soporta en la literatura, cada zona del cerebro muestreado trabaja en conjunto en respuesta al estímulo o actividad cognitiva. Esto se puede observar en la correlación positiva existente entre los catorce electrodos.

Hasta este punto, se ha considerado como ventaja la disponibilidad de los catorce electrodos que componen el dispositivo EPOC+. Sin embargo, fue importante para la investigación conocer de manera formal aquellos electrodos que inciden de manera determinante en la distinción de las dos intenciones de movimiento. Para ello, la aplicación de la teoría de testores resultó adecuado para responder este cuestionamiento. Con la teoría de testores, se extrajo un conjunto de testores típicos que representan subconjuntos mínimos de características capaces discernir la clase

a la que pertenece un objeto en particular. Con ello, se disminuyó la dimensionalidad del problema de clasificación y, por lo tanto, el modelo de clasificación tuvo menores requerimientos computacionales. Sin embargo, lo más importante a resaltar es el uso del peso informacional como medida de significancia de cada electrodo en la clasificación de las intenciones de movimiento. De la misma forma, es importante recalcar que los nodos con mayor valor de peso informacional coinciden con zonas del hemisferio izquierdo relacionadas, tanto con el movimiento como con la intención del movimiento, así como asociadas al control de movimientos de las extremidades derechas.

De la misma forma, es importante recalcar que, al llevar a cabo experimentación con intenciones de abrir y cerrar de la mano derecha de los sujetos de prueba, los nodos con mayor valor de peso informacional resultan ser del hemisferio izquierdo, asociado al control de movimiento de las extremidades derechas, dado el hecho de trabajar con muestreo de señales del brazo derecho de los sujetos de prueba. Más específicamente, los nodos con mayor peso informacional corresponden a zonas de los lóbulos frontal, parietal y occipital derechos, los cuales son relacionadas al movimiento y su planificación, el procesamiento de la sensación y la percepción, así como tareas relacionadas a la memoria; funciones cruciales en la evocación de la intención de movimiento.

Por su parte, se analizaron diferentes clasificadores como el clasificador bayesiano simple (naive Bayes), las máquinas de soporte vectorial y las redes neuronales artificiales. Específicamente, el clasificador bayesiano simple resultó ser el más simple de los mecanismos analizados. Sin embargo, fue muy robusto en la clasificación de las señales del repositorio del estado del ojo. Lo que significa que el bayesiano simple resulta ser un punto de comparación inicial para la implementación de otros mecanismos.

Las máquinas de soporte vectorial y las redes neuronales artificiales se probaron directamente con señales de intención de movimiento. Como resultado se obtuvieron desempeños de clasificación muy similares. Donde, después de un

análisis estadístico existe una diferencia significativa entre el modelo de máquina de soporte vectorial y el desempeño de la red neuronal artificial. De esta manera, se concluyó en utilizar la red neuronal pues, maximiza el desempeño de la clasificación. Al final de este estudio, no solo se contó con la elección de un clasificador, además, se contó con la afinación de los parámetros. Es decir, se expusieron los valores que permitieron maximizar el desempeño de la clasificación de señales electroencefalográficas con la intención de abrir y cerrar la mano.

Finalmente, como se mencionó anteriormente, la intención de movimiento es una representación mental del movimiento sin la intervención muscular, es decir, sin movimiento físico real. Para este proyecto de tesis, se centró en la intención de movimiento cinestésico referente a la evocación de las sensaciones de movimiento en primera persona. La intención de movimiento es toda una operación cognitiva, consiente y auto intencionada. Es un proceso complejo a nivel cerebral pues requiere de la participación de múltiples zonas, tanto corticales como subcorticales.

Todo comienza con el sistema límbico relacionado con el control de la conducta emocional y motivacional, especialmente relacionado con el control motivacional del aprendizaje y los sentimientos de placer y castigo [348]. Se involucran, también, los ganglios basales y el cerebelo, como zonas subcorticales relacionadas al aprendizaje y preparación motriz. Por su parte, los ganglios basales poseen funciones de control motriz y funciones ejecutivas. Mientras que el cerebelo funciona como un módulo de retroalimentación del movimiento, contribuyendo como un sistema de representación interna del movimiento y su coordinación.

En zonas corticales, la intención de movimiento activa la corteza frontal relacionado con movimientos voluntarios o deliberados, además de poseer la representación del cuerpo humano a través del homúnculo de Penfield. Finalmente, la corteza parietal que presenta mayor activación en la intención de movimiento cinestésico y cuando el sujeto posee mayor experiencia en el movimiento a realizar. La corteza parietal es la zona que contribuye en la ejecución de acciones en un correcto orden generando un modelo interno del movimiento.

Así, gracias a la complejidad de la práctica de intención de movimiento, se obtienen resultados en áreas como la rehabilitación y el deporte, funcionando como puerta trasera al sistema motor. De esta manera, los pacientes pueden recuperar su movilidad gracias a unos de impulsos voluntarios, así como el aprendizaje de movimientos específicos y finos utilizados en algunos deportes.



Bibliografía

- [1] S. Marengo, “Tipos de imaginación motora y procesamiento predictivo,” *Poiésis*, vol. 1, pp. 58–71, Apr. 2018, doi: 10.21501/16920945.2787.
- [2] R. Carino Escobar, J. Cantillo Negrete, J. Gutiérrez Martínez, and R. Vázquez, “Decodificación de imaginación motora en la señal de electroencefalografía mediante mapas auto-organizados,” *Rev. del Cent. Investig. la Univ. La Salle*, vol. 12, no. 45, pp. 107–125, 2016, [Online]. Available: <https://www.redalyc.org/pdf/342/34247483006.pdf>.
- [3] F. Di Rienzo *et al.*, “Online and Offline Performance Gains Following Motor Imagery Practice: A Comprehensive Review of Behavioral and Neuroimaging Studies,” *Front. Hum. Neurosci.*, vol. 10, p. 315, 2016, doi: 10.3389/fnhum.2016.00315.
- [4] L. Habib Mireles, “Presencia de los pilares de la industria 4.0 en la formación de ingenieros en el noreste de México,” *Rev. Cuba. Educ. Super.*, vol. 41, 2022.
- [5] J. Hamilton Ortiz, Ed., *Industry 4.0 - Current Status and Future Trends*. London: IntechOpen, 2020.
- [6] M. Lom, O. Pribyl, and M. Svitek, “Industry 4.0 as a part of smart cities,” in *2016 Smart Cities Symposium Prague (SCSP)*, May 2016, pp. 1–6, doi: 10.1109/SCSP.2016.7501015.
- [7] M. Álvarez Vega, L. M. Quirós Mora, and M. V. Cortés Badilla, “Inteligencia artificial y aprendizaje automático en medicina,” *Rev. Médica Sinerg.*, vol. 5, no. 8, p. e557, Aug. 2020, doi: 10.31434/rms.v5i8.557.
- [8] F. Bonete and M. Sánchez Martínez, “‘Smart City’ y patrimonio cultural: las aplicaciones móviles de ciudades patrimonio de la humanidad españolas,” in *Ciudad y Comunicación*, 1st ed., Madrid: Grupo de Investigación Arte, Arquitectura y Comunicación en la Ciudad Contemporánea. Universidad Complutense de Madrid, 2016, pp. 475–482.
- [9] P. Chhikara, N. Jain, R. Tekchandani, and N. Kumar, “Data dimensionality reduction techniques for Industry 4.0: Research results, challenges, and future research directions,” *Softw. Pract. Exp.*, vol. 52, no. 3, pp. 658–688, Mar. 2022, doi: 10.1002/spe.2876.
- [10] V. Arias Ing *et al.*, “Una introducción a las aplicaciones de la inteligencia

- artificial en Medicina: Aspectos históricos,” *Rev. Latinoam. Hipertens.*, vol. 14, no. 5, pp. 590–600, 2019, [Online]. Available: <https://search.proquest.com/docview/2344256687?accountid=6724>.
- [11] S. Barzallo and P. Barzallo, “La Inteligencia Artificial en Medicina,” *Ateneo*, vol. 21, no. 2, pp. 81–94, 2020, Accessed: Sep. 14, 2020. [Online]. Available: <http://colegiomedicosazuay.ec/ojs/index.php/ateneo/article/view/102>.
- [12] V. Chávez Saenz, D. Torres Ramírez, J. Herrera Ogaz, and A. Hernández Rodríguez, “Adquisición y análisis de señales electroencefalográficas utilizando el dispositivo Emotiv EPOC+,” vol. 3, no. 7. ECOFARN, Bolivia, pp. 107–118, 2016, Accessed: Sep. 21, 2020. [Online]. Available: https://ecorfan.org/bolivia/researchjournals/Tecnologia_e_innovacion/vol3num7/Revista_de_Tecnologia_e_Innovación_V3_N7.pdf#page=116.
- [13] A. Ibanez and A. García, *Que son las Neurociencias*. Ediciones Paidós, 2015.
- [14] L. Espinosa, “Electroencefalografía Inalámbrica: Una mirada actual y propuesta de sistema portátil.” Universidad Técnica Federico Santa María, Chile, 2016, [Online]. Available: http://profesores.elo.utfsm.cl/~agv/elo323/2s15/projects/reports/LeonardoEspinosa_WirelessEEG.pdf.
- [15] E. Urrestarazu and J. Iriarte, “Mathematical analyses in the study of electroencephalographic signals,” *Rev. Neurol.*, vol. 41, no. 5, pp. 423–434, 2005, [Online]. Available: <https://dadun.unav.edu/handle/10171/22783>.
- [16] S. Siuly, Y. Li, and Y. Zhang, “Electroencephalogram (EEG) and Its Background,” in *EEG Signal Analysis and Classification*, 2016, pp. 3–21.
- [17] M. de Bardeci, C. T. Ip, and S. Olbrich, “Deep learning applied to electroencephalogram data in mental disorders: A systematic review,” *Biol. Psychol.*, vol. 162, p. 108117, May 2021, doi: 10.1016/j.biopsycho.2021.108117.
- [18] R. Arango and J. J. Naranjo, “Desarrollo de una herramienta de arquitectura abierta para la visualización y análisis de señales EEG,” Universidad Tecnológica de Pereira, Colombia, 2010.
- [19] C. A. Martínez Medina, “Máquinas de Soporte Vectorial en la Interpretación de Movimiento para Videojuegos Utilizando Interfaces Cerebro-Computadora,” Universidad Autónoma de Aguascalientes, Aguascalientes, México, 2016.
- [20] E. R. Escobar Sailema and D. A. Zurita Arboleda, “Diseño y Construcción de un Prototipo de Mano Robótica con Arquitectura Antropomórfica,” ESPE, Universidad de la Fuerzas Armadas, Ecuador, 2017.
- [21] R. Ramadan, R. S., M. A. Elshahed, and R. A. Ali, “Basics of Brain Computer Interface,” in *Brain-Computer Interfaces*, vol. 74, Springer, Ed. Suiza: Springer

International Publishing Switzerland, pp. 31–50.

- [22] J. De la Torre Abaitua, “Procesado de Señales EEG para un Interfaz Cerebro-Máquina (BCI),” Universidad Carlos III de Madrid, Madrid, España, 2012.
- [23] N. Angulo, J. Sanz, V. Malavé, M. Barrera, H. Spinetti, and P. Guillén, “Máquinas de aprendizaje para clasificar señales electroencefalográficas,” *Rev. Av. en Sist. e Informática*, vol. 6, p. 6, [Online]. Available: <http://bdigital.unal.edu.co/18628/1/14497-43459-1-PB.pdf>.
- [24] J. R. de la O Chávez, “Interfaz Cerebro-Computadora para el control de un cursor basada en ondas cerebrales,” Universidad Autónoma Metropolitana de Azcapotzalco.
- [25] J. Arriola, “Representación Matemática de Ondas Cerebrales,” Universidad Nacional del Sur, Bahía Blanca, Argentina, 2016.
- [26] O. Santa Cruz, L. Del Mar Ramírez, and F. Trujillo Romero, “Técnicas de aprendizaje automático aplicadas a electroencefalogramas,” *Research in Computer Science*, vol. 113. Instituto Politécnico Nacional, México, pp. 53–65, 2016, [Online]. Available: [http://www.rcs.cic.ipn.mx/2016_113/Tecnicas de aprendizaje automatico aplicadas a electroencefalogramas.pdf](http://www.rcs.cic.ipn.mx/2016_113/Tecnicas%20de%20aprendizaje%20automatico%20aplicadas%20a%20electroencefalogramas.pdf).
- [27] J. E. Arango, J. C. Mazo, and A. P. Palacio, “Sistema para Rehabilitación del Síndrome del Miembro Fantasma utilizando Interfaz Cerebro-Computador y Realidad Aumentada,” *RISTI - Rev. Ibérica Sist. e Tecnol. Informação*, pp. 93–106, 2013, [Online]. Available: http://www.scielo.mec.pt/scielo.php?script=sci_arttext&pid=S1646-98952013000100008&nrm=iso.
- [28] M. A. Rosales-Reynoso, C. I. Juárez-Vázquez, and P. Barros-Núñez, “Evolution and genomics of the human brain,” *Neurología*, vol. 33, no. 4. Spanish Society of Neurology, pp. 254–265, May 01, 2018, doi: 10.1016/j.nrl.2015.06.002.
- [29] J. Viosca, *El Cerebro*, 1st ed. México: National Geographic, 2017.
- [30] B. U. Forstmann, M. C. Keuken, and A. Alkemade, “An Introduction to Human Brain Anatomy,” in *An Introduction to Model-Based Cognitive Neuroscience*, New York, NY: Springer New York, 2015, pp. 71–89.
- [31] C. Cuya Mamani, “EL CEREBRO HUMANO, UNA PERSPECTIVA TRANSDISCIPLINARIA,” *Cienc. Desarro.*, no. 17, pp. 104–110, Apr. 2019, doi: 10.33326/26176033.2014.17.424.
- [32] K. H. Jawabri and S. Sharma, “Physiology, Cerebral Cortex Functions,” *National Library of Medicine*, Apr. 28, 2022. <https://www.ncbi.nlm.nih.gov/books/NBK538496/> (accessed Sep. 28, 2022).
- [33] J. G. Beaumont, *Introduction to Neuropsychology*, 2nd ed. New York, USA:

The Guilford Press, 2008.

- [34] J. A. Portellano, *Introducción a la neuropsicología*. España: McGRAW-HILL, 2005.
- [35] D. F. Cechetto and J. C. Topolovec, “Cerebral Cortex,” in *Encyclopedia of the Human Brain*, Elsevier, 2002, pp. 663–679.
- [36] S. Muñoz Collado, “La corteza cerebral: morfología, histología y localización funcional,” vol. 2018. psicoactiva.com, 2017, [Online]. Available: <https://www.psicoactiva.com/blog/la-corteza-cerebral-morfologia-histologia-localizacion-funcional/>.
- [37] M. Larvie and B. Fischl, “Volumetric and fiber-tracing MRI methods for gray and white matter,” in *Handbook of Clinical Neurology*, vol. 135, 2016, pp. 39–60.
- [38] J. Mateu-Mollá, “Los 4 lóbulos del cerebro,” *medicoplus.com*, 2019. <https://medicoplus.com/neurologia/lobulos-del-cerebro> (accessed Sep. 22, 2020).
- [39] S. Muñoz Collado, “Los lóbulos frontales y su relación con las emociones,” vol. 2018. PsicoActiva.com, 2017, [Online]. Available: <https://www.psicoactiva.com/blog/los-lobulos-frontales-relacion-las-emociones/>.
- [40] O. Guy-Evans and S. Mcleod, “Frontal Lobe: Function, Location and Structure,” *Simply Psychology*, May 08, 2021. <https://www.simplypsychology.org/frontal-lobe.html> (accessed Sep. 28, 2022).
- [41] G. Sendic and D. Mytilinaios, “Frontal Lobe,” *Kenhub Neuroanatomy*, Jul. 27, 2022. .
- [42] A. Figueroba, “Los humúnculos sensorial y motor de Penfield: ¿qué son?,” *Psicología y Mente*, Jun. 23, 2017. <https://psicologiaymente.com/neurociencias/homunculos-penfield> (accessed Sep. 29, 2022).
- [43] O. Guy-Evans, “Parietal Lobe: Definition, Functions, and Location,” *Simply Psychology*, Apr. 13, 2021. <https://www.simplypsychology.org/parietal-lobe.html> (accessed Sep. 25, 2022).
- [44] S. Muñoz Collado, “El lóbulo parietal: anatomía y función,” vol. 2018. psicoactiva.com, 2017, [Online]. Available: <https://www.psicoactiva.com/blog/lobulo-parietal-anatomia-funcion/>.
- [45] S. Shahid and E. O. Johnson, “Parietal Lobe,” *Kenhub*, Jul. 09, 2022. <https://www.kenhub.com/en/library/anatomy/parietal-lobe> (accessed Sep. 29, 2022).
- [46] E. Kumral, F. E. Bayam, and H. N. Özdemir, “Cognitive and Behavioral

Disorders in Patients with Precuneal Infarcts,” *Eur. Neurol.*, vol. 84, no. 3, pp. 157–167, 2021, doi: 10.1159/000513098.

- [47] “Brain,” *Cleveland Clinic*, Feb. 2022. <https://my.clevelandclinic.org/health/body/22638-brain> (accessed Sep. 29, 2022).
- [48] S. Ferreira and D. Tempny, “Temporal Lobe,” *Kenhub*, Aug. 04, 2022. <https://www.kenhub.com/en/library/anatomy/temporal-lobe> (accessed Sep. 30, 2022).
- [49] O. Guy-Evans and S. Mcleod, “Temporal Lobe: Definition, Function, Location & Structure,” *Simply Psychology*, Apr. 12, 2021. <https://www.simplypsychology.org/temporal-lobe.html> (accessed Sep. 30, 2022).
- [50] S. Muñoz Collado, “Lóbulos temporales, anatomía y función,” vol. 2018. *psicoactiva.com*, 2017, [Online]. Available: <https://www.psicoactiva.com/blog/lobulo-temporal-anatomia-funcion/>.
- [51] S. Muñoz Collado, “Lóbulo occipital: anatomía y función,” vol. 2018. *psicoactiva.com*, 2017, [Online]. Available: <https://www.psicoactiva.com/blog/lobulo-occipital-anatomia-funcion/>.
- [52] S. Stewart and E. Pirie, “Occipital Lobe,” *Kenhub*, May 25, 2022. <https://www.kenhub.com/en/library/anatomy/occipital-lobe> (accessed Sep. 30, 2022).
- [53] A. Rehman and Y. Al Khalili, “Neuroanatomy, Occipital Lobe,” *National Library of Medicine*, Jul. 31, 2021. <https://www.ncbi.nlm.nih.gov/books/NBK544320/> (accessed Sep. 30, 2022).
- [54] O. Guy-Evans and S. Mcleod, “Occipital Lobe: Definition, Function, and Location,” *Simply Psychology*, Apr. 19, 2021. <https://www.simplypsychology.org/occipital-lobe.html> (accessed Sep. 30, 2022).
- [55] A. Andrusca and D. Mytilinaios, “Basal ganglia,” *Kenhub Neuroanatomy*, Aug. 01, 2022. <https://www.kenhub.com/en/library/anatomy/basal-ganglia> (accessed Oct. 04, 2022).
- [56] T. M. Florio *et al.*, “The Basal Ganglia: More than just a switching device,” *CNS Neurosci. Ther.*, vol. 24, no. 8, pp. 677–684, Aug. 2018, doi: 10.1111/cns.12987.
- [57] H. A. González-Usigli, “Enfermedad de Parkinson,” *Manual MSD Versión para profesionales*, Feb. 2022. <https://www.msmanuals.com/es/professional/trastornos-neurológicos/trastornos-del-movimiento-y-cerebelosos/enfermedad-de-parkinson> (accessed Nov. 07, 2022).

- TESIS TESIS TESIS TESIS TESIS
- [58] O. Castellero Mimenza, "Ganglios basales: anatomía y funciones," *Psicología y Mente*, Nov. 01, 2016. <https://psicologiaymente.com/neurociencias/ganglios-basales> (accessed Oct. 04, 2022).
- [59] I. Junquera and R. Junquera, "Definición - Qué es ganglios bases o núcleos de la base," *FisioOnline - Todo sobre fisioterapia*. <https://www.fisioterapia-online.com/glosario/ganglios-basales-o-nucleos-de-la-base> (accessed Oct. 04, 2022).
- [60] A. Figueroba, "Cuerpo estriado: estructura, funciones y trastornos asociados," *Psicología y Mente*, Apr. 26, 2017. <https://psicologiaymente.com/neurociencias/cuerpo-estriado> (accessed Oct. 05, 2022).
- [61] O. Castellero Mimenza, "Núcleo caudado: características, funciones y trastornos," *Psicología y Mente*, Apr. 30, 2017. <https://psicologiaymente.com/neurociencias/nucleo-caudado> (accessed Oct. 05, 2022).
- [62] A. Figueroba, "Putamen: estructura, funciones y trastornos relacionados," *Psicología y Mente*, Apr. 30, 2017. <https://psicologiaymente.com/neurociencias/putamen> (accessed Oct. 05, 2022).
- [63] A. Figueroba, "Globo pálido: estructura, funciones y trastornos asociados," *Psicología y Mente*, Apr. 29, 2017. <https://psicologiaymente.com/neurociencias/globo-palido> (accessed Oct. 05, 2022).
- [64] A. Figueroba, "Sustancia negra: qué es, funciones y trastornos relacionados," *Psicología y Mente*, Mar. 10, 2017. <https://psicologiaymente.com/neurociencias/sustancia-negra> (accessed Oct. 05, 2022).
- [65] H. J. Groenewegen, "The Basal Ganglia and Motor Control," *Neural Plast.*, vol. 10, no. 1–2, pp. 107–120, 2003, doi: 10.1155/NP.2003.107.
- [66] S. Muñoz Collado, "El Cerebelo: anatomía y fisiología," *PsicoActiva: Fisiología y Neurociencias*, Jun. 28, 2021. <https://www.psicoactiva.com/blog/cerebelo-anatomia-fisiologia/> (accessed Oct. 06, 2022).
- [67] E. D'Angelo, "Physiology of the cerebellum," in *Handbook of Clinical Neurology*, vol. 154, 2018, pp. 85–108.
- [68] C. Leopold and S. Han, "Everything you need to know about the cerebellum," *Medical News Today*, Aug. 24, 2022. <https://www.medicalnewstoday.com/articles/313265> (accessed Oct. 07, 2022).

- [69] A. Torres, "Cerebelo humano: sus partes y funciones," *Psicología y Mente*, Jul. 18, 2016. <https://psicologiaymente.com/neurociencias/cerebelo-humano-partes-funciones> (accessed Oct. 06, 2022).
- [70] Guy-Evans Olivia and S. Mcleod, "Cerebellum Functions, Structure, and Location," *Simply Psychology*, Apr. 12, 2021. <https://www.simplypsychology.org/what-is-the-cerebellum.html> (accessed Sep. 26, 2022).
- [71] M. J. Wagner and L. Luo, "Neocortex–Cerebellum Circuits for Cognitive Processing," *Trends Neurosci.*, vol. 43, no. 1, pp. 42–54, Jan. 2020, doi: 10.1016/j.tins.2019.11.002.
- [72] H. Jacobi, J. Faber, D. Timmann, and T. Klockgether, "Update cerebellum and cognition," *J. Neurol.*, vol. 268, no. 10, pp. 3921–3925, Oct. 2021, doi: 10.1007/s00415-021-10486-w.
- [73] W. S. Van Hoogstraten and C. I. De Zeeuw, "Decoding the infrastructure of the cerebellum," *Elife*, vol. 9, 2020, doi: 10.7554/ELIFE.60852.
- [74] M. Byrne and U. Zehra, "Cerebellum histology," *Kenhub Anatomy*, Jul. 22, 2022. <https://www.kenhub.com/en/library/anatomy/histology-of-the-cerebellum> (accessed Oct. 07, 2022).
- [75] B. Cengiz and H. E. Boran, "The role of the cerebellum in motor imagery," *Neurosci. Lett.*, vol. 617, pp. 156–159, Mar. 2016, doi: 10.1016/j.neulet.2016.01.045.
- [76] S. S.-H. Wang, A. D. Kloth, and A. Badura, "The Cerebellum, Sensitive Periods, and Autism," *Neuron*, vol. 83, no. 3, pp. 518–532, Aug. 2014, doi: 10.1016/j.neuron.2014.07.016.
- [77] L. F. Koziol *et al.*, "Consensus Paper: The Cerebellum's Role in Movement and Cognition," *The Cerebellum*, vol. 13, no. 1, pp. 151–177, Feb. 2014, doi: 10.1007/s12311-013-0511-x.
- [78] R. L. Buckner, "The Cerebellum and Cognitive Function: 25 Years of Insight from Anatomy and Neuroimaging," *Neuron*, vol. 80, no. 3, pp. 807–815, Oct. 2013, doi: 10.1016/j.neuron.2013.10.044.
- [79] M. Ito, "Control of mental activities by internal models in the cerebellum," *Nat. Rev. Neurosci.*, vol. 9, no. 4, pp. 304–313, Apr. 2008, doi: 10.1038/nrn2332.
- [80] J. L. Quintanar Stephano, D. Calderon Vallejo, and M. L. González Torres, *¿Qué es bueno para la memoria?*, 1st ed. Aguascalientes: Universidad Autónoma de Aguascalientes, 2016.
- [81] H. Pasantes, *De neuronas, emociones y motivaciones*, 3rd ed. Ciudad de México: Fondo de Cultura Económica, 2018.
- [82] A. Woodruff, "What is a neuron?," *Queensland Brain Institute*.

- <https://qbi.uq.edu.au/brain/brain-anatomy/what-neuron> (accessed Oct. 10, 2022).
- [83] C. Serrano and A. Torres, “Neurona,” *Kenhub Anatomía*, Aug. 02, 2022. <https://www.kenhub.com/es/library/anatomia-es/neurona> (accessed Oct. 10, 2022).
- [84] I. Junquera and R. Junquera, “Definición - Qué es sinapsis o comunicación neuronal,” *FisioOnline - Todo sobre fisioterapia*, May 2021. <https://www.fisioterapia-online.com/glosario/sinapsis-o-comunicacion-neuronal> (accessed Oct. 10, 2022).
- [85] “Sinapsis, el lenguaje de las neuronas en el cerebro,” *National Geographic España*, Apr. 27, 2019.
- [86] M. Medina Carmona and J. V. Sánchez Andrés, *La Electricidad del Cerebro: Los Secretos de la Actividad Cerebral*, 1st ed. México: National Geographic, 2017.
- [87] S. Muñoz Collado, “Sinapsis neuronal: ¿Qué es? Conexiones sinápticas y tipos de sinapsis,” *PsicoActiva Fisiología y Neurociencias*, Dec. 16, 2021. <https://www.psicoactiva.com/blog/la-sinapsis-neuronal-tipos-sinapsis/> (accessed Oct. 10, 2022).
- [88] O. Izaguirre, “Ciclo de Neurociencias. Semana 1: Neuronas en las tripas ¿Y para qué? parte I,” *steemit.com*, 2017. <https://steemit.com/spanish/@psicomar/ciclo-de-neurociencias-semana-1-neuronas-en-las-tripas-y-para-que-parte-i> (accessed Nov. 25, 2019).
- [89] S. Muñoz Collado, “La neurona: morfología y estructura,” *PsicoActiva Fisiología y Neurociencias*, Dec. 13, 2021. <https://www.psicoactiva.com/blog/psicofisiologia/la-neurona-morfologia-estructural/> (accessed Oct. 10, 2022).
- [90] Khan Academy, “Función y estructura de la neurona,” *La neurona y el sistema nervioso*. <https://es.khanacademy.org/science/biology/human-biology/neuron-nervous-system/a/overview-of-neuron-structure-and-function> (accessed Oct. 10, 2022).
- [91] V. Nicholson, N. Watts, Y. Chani, and J. W. L. Keogh, “Motor imagery training improves balance and mobility outcomes in older adults: a systematic review,” *J. Physiother.*, vol. 65, no. 4, pp. 200–207, 2019, doi: <https://doi.org/10.1016/j.jphys.2019.08.007>.
- [92] C. Rousseau, M. Barbiero, T. Pozzo, C. Papaxanthis, and O. White, “Actual and Imagined Movements Reveal a Dual Role of the Insular Cortex for Motor Control,” *Cereb. Cortex*, vol. 31, no. 5, pp. 2586–2594, Mar. 2021, doi: [10.1093/cercor/bhaa376](https://doi.org/10.1093/cercor/bhaa376).
- [93] O. A. Mokienko, L. A. Chernikova, A. A. Frolov, and P. D. Bobrov, “Motor

- Imagery and Its Practical Application,” *Neurosci. Behav. Physiol.*, vol. 44, no. 5, Jun. 2014, doi: 10.1007/s11055-014-9937-y.
- [94] C. Ruffino, J. Gaveau, C. Papaxanthis, and F. Lebon, “An acute session of motor imagery training induces use-dependent plasticity,” *Sci. Rep.*, vol. 9, no. 1, p. 20002, 2019, doi: 10.1038/s41598-019-56628-z.
- [95] R. Dickstein and J. E. Deutsch, “Motor Imagery in Physical Therapist Practice,” *Phys. Ther.*, vol. 87, no. 7, pp. 942–953, Jul. 2007, doi: 10.2522/ptj.20060331.
- [96] S. Pilgramm *et al.*, “Motor imagery of hand actions: Decoding the content of motor imagery from brain activity in frontal and parietal motor areas,” *Hum. Brain Mapp.*, vol. 37, no. 1, pp. 81–93, Jan. 2016, doi: 10.1002/hbm.23015.
- [97] G. Bonassi, M. Biggio, A. Bisio, P. Ruggeri, M. Bove, and L. Avanzino, “Provision of somatosensory inputs during motor imagery enhances learning-induced plasticity in human motor cortex,” *Sci. Rep.*, vol. 7, Dec. 2017, doi: 10.1038/s41598-017-09597-0.
- [98] V. P. Nicholson, J. W. L. Keogh, and N. L. L. Choy, “Can a single session of motor imagery promote motor learning of locomotion in older adults? A randomized controlled trial,” *Clin. Interv. Aging*, vol. 13, 2018, doi: 10.2147/CIA.S164401.
- [99] T. Schack, K. Essig, C. Frank, and D. Koester, “Mental representation and motor imagery training,” *Front. Hum. Neurosci.*, vol. 8, 2014, doi: 10.3389/fnhum.2014.00328.
- [100] S. Kumar, A. Sharma, K. Mamun, and T. Tsunoda, “A Deep Learning Approach for Motor Imagery EEG Signal Classification,” in *2016 3rd Asia-Pacific World Congress on Computer Science and Engineering (APWC on CSE)*, Dec. 2016, doi: 10.1109/APWC-on-CSE.2016.017.
- [101] S. R. Sreeja, J. Rabha, K. Y. Nagarjuna, D. Samanta, P. Mitra, and M. Sarma, “Motor Imagery EEG Signal Processing and Classification Using Machine Learning Approach,” in *2017 International Conference on New Trends in Computing Sciences (ICTCS)*, Oct. 2017, doi: 10.1109/ICTCS.2017.15.
- [102] T. Kanthack, “Interdependent relationships between the mental representation and psychophysiological correlates of action,” 2018.
- [103] A. Guillot, F. Di Rienzo, and C. Collet, “The Neurofunctional Architecture of Motor Imagery,” in *Advanced Brain Neuroimaging Topics in Health and Disease - Methods and Applications*, InTech, 2014.
- [104] K. J. Miller, G. Schalk, E. E. Fetz, M. den Nijs, J. G. Ojemann, and R. P. N. Rao, “Cortical activity during motor execution, motor imagery, and imagery-based online feedback,” *Proc. Natl. Acad. Sci.*, vol. 107, no. 9, pp. 4430–4435, Mar. 2010, doi: 10.1073/pnas.0913697107.

- [105] T. Mulder, “Motor imagery and action observation: cognitive tools for rehabilitation,” *J. Neural Transm.*, vol. 114, no. 10, Oct. 2007, doi: 10.1007/s00702-007-0763-z.
- [106] E. Bagarinao *et al.*, “Improved Volitional Recall of Motor-Imagery-Related Brain Activation Patterns Using Real-Time Functional MRI-Based Neurofeedback,” *Front. Hum. Neurosci.*, vol. 12, Apr. 2018, doi: 10.3389/fnhum.2018.00158.
- [107] A. M. Batula, J. A. Mark, Y. E. Kim, and H. Ayaz, “Comparison of Brain Activation during Motor Imagery and Motor Movement Using fNIRS,” *Comput. Intell. Neurosci.*, vol. 2017, pp. 1–12, 2017, doi: 10.1155/2017/5491296.
- [108] F. Ramón Romero, A. Mansilla Olivares, and A. Rivera Cruz, “La corteza motora,” in *Neurofisiología para estudiantes*, .
- [109] J. Decety, “The neurophysiological basis of motor imagery,” *Behav. Brain Res.*, vol. 77, no. 1–2, May 1996, doi: 10.1016/0166-4328(95)00225-1.
- [110] N. Mizuguchi, H. Nakata, Y. Uchida, and K. Kanosue, “Motor imagery and sport performance,” *J. Phys. Fit. Sport. Med.*, vol. 1, no. 1, pp. 103–111, 2012, doi: 10.7600/jpfsm.1.103.
- [111] Y. K. Kim, E. Park, A. Lee, C.-H. Im, and Y.-H. Kim, “Changes in network connectivity during motor imagery and execution,” *PLoS One*, vol. 13, no. 1, p. e0190715, Jan. 2018, doi: 10.1371/journal.pone.0190715.
- [112] M. K. Fleming, C. M. Stinear, and W. D. Byblow, “Bilateral parietal cortex function during motor imagery,” *Exp. Brain Res.*, vol. 201, no. 3, pp. 499–508, Mar. 2010, doi: 10.1007/s00221-009-2062-4.
- [113] A. Guillot, C. Collet, V. A. Nguyen, F. Malouin, C. Richards, and J. Doyon, “Brain activity during visual versus kinesthetic imagery: An fMRI study,” *Hum. Brain Mapp.*, vol. 30, no. 7, pp. 2157–2172, Jul. 2009, doi: 10.1002/hbm.20658.
- [114] E. Naito *et al.*, “Internally Simulated Movement Sensations during Motor Imagery Activate Cortical Motor Areas and the Cerebellum,” *J. Neurosci.*, vol. 22, no. 9, pp. 3683–3691, May 2002, doi: 10.1523/JNEUROSCI.22-09-03683.2002.
- [115] M. Lotze and U. Halsband, “Motor imagery,” *J. Physiol.*, vol. 99, no. 4–6, pp. 386–395, Jun. 2006, doi: 10.1016/j.jphysparis.2006.03.012.
- [116] M. G. Paulin, “The Role of the Cerebellum in Motor Control and Perception,” *Brain. Behav. Evol.*, vol. 41, no. 1, pp. 39–50, 1993, doi: 10.1159/000113822.
- [117] D. Milardi *et al.*, “The Cortico-Basal Ganglia-Cerebellar Network: Past, Present and Future Perspectives,” *Front. Syst. Neurosci.*, vol. 13, Oct. 2019, doi: 10.3389/fnsys.2019.00061.

- [118] A. Errante and L. Fogassi, “Activation of cerebellum and basal ganglia during the observation and execution of manipulative actions,” *Sci. Rep.*, vol. 10, no. 1, p. 12008, Dec. 2020, doi: 10.1038/s41598-020-68928-w.
- [119] A. Carrillo Ramírez, O. Garatejo Escobar, and W. Pineda Ríos, “Análisis multivariado de datos funcionales aplicado a curvas de encefalogramas,” *Comunicaciones en Estadística*, vol. 10. Universidad Santo Tomás, Colombia NV - 1, pp. 129–144, 2017, [Online]. Available: https://www.researchgate.net/publication/318437969_Analisis_de_datos_funcionales_aplicado_en_electroencefalogramas_agrupamiento_por_k-medias_funcional.
- [120] J. S. Kumar and P. Bhuvaneshwari, “Analysis of Electroencephalography (EEG) Signals and Its Categorization—A Study,” *Procedia Eng.*, vol. 38, 2012, doi: 10.1016/j.proeng.2012.06.298.
- [121] A. Reyes Rueda, “Interfaz Cerebro Computador Mediante la Clasificación de Señales Electroencefalográficas,” Pontificia Universidad Javeriana, Bogotá, Colombia, 2013.
- [122] P. J.R., L. J. Varela Lara, C. Alvarado Serrado, and P. S. Luna Lozano, “Sistema Portátil para el Análisis de Potenciales Evocados en Señales de Electroencefalografía,” *Memorias XXXIX Congr. Nac. Ing. Biomédica*, vol. 3, no. 1, pp. 107–125, 2015, doi: 10.24254/CNIB.16.19.
- [123] A. Biasiucci, B. Franceschiello, and M. M. Murray, “Electroencephalography,” *Curr. Biol.*, vol. 29, no. 3, Feb. 2019, doi: 10.1016/j.cub.2018.11.052.
- [124] G. Coro, G. Masetti, P. Bonhoeffer, and M. Betcher, “Distinguishing Violinists and Pianists Based on Their Brain Signals,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2019, vol. 11727 LNCS, pp. 123–137, doi: 10.1007/978-3-030-30487-4_11.
- [125] S. A. Keenan, O. Carrillo, and H. Casseres, “Electroencephalography,” in *Encyclopedia of Sleep*, Elsevier, 2013.
- [126] A. Santillan Guzman, H. Z. Ramírez Uriarte, J. J. Oliveros Oliveros, M. M. Morin Castillo, and H. Ramírez Díaz, “Interfaz Gráfica Intuitiva para el Procesamiento de Señales EEG,” *Memorias DEI Congr. Nac. Ing. Biomédica*, vol. 5, no. 1, pp. 146–149, 2018, doi: dx.doi.org/10.24254/CNIB.18.20.
- [127] A. Craik, Y. He, and J. L. Contreras-Vidal, “Deep learning for electroencephalogram (EEG) classification tasks: a review,” *J. Neural Eng.*, vol. 16, no. 3, p. 031001, Jun. 2019, doi: 10.1088/1741-2552/ab0ab5.
- [128] Y. Roy, H. Banville, I. Albuquerque, A. Gramfort, T. H. Falk, and J. Faubert, “Deep learning-based electroencephalography analysis: a systematic review,” *J. Neural Eng.*, vol. 16, no. 5, p. 51001, Aug. 2019, doi: 10.1088/1741-

2552/ab260c.

- [129] F. Ramos Argüelles, G. Morales, S. Egozcue, R. M. Pabón, and M. T. Alonso, "Técnicas de electroencefalografía: principios y aplicaciones clínicas," *An. Sist. Sanit. Navar.*, vol. 32, pp. 69–82, Jun. 2009, [Online]. Available: http://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1137-66272009000600006&nrm=iso.
- [130] F. Maureira Cid and E. Flores Ferro, "Electroencefalografía (EEG) y diversas manifestaciones del movimiento: una revisión del 2000 al 2017," *EmásF, Rev.*, vol. 9, no. 51, pp. 48–63, 2018, [Online]. Available: https://www.researchgate.net/publication/323559690_Electroencefalografia_EEG_y_diversas_manifestaciones_del_movimiento_una_revisión_del_2000_al_2017.
- [131] A. E. García Domínguez, "Análisis de ondas cerebrales para determinar emociones a partir de estímulos visuales," Universidad Veracruzana, 2015.
- [132] J. A. Aznar Casanova, "Las ondas cerebrales," *Psicología de la percepción visual*. <http://www.ub.edu/pa1/node/130> (accessed Nov. 14, 2019).
- [133] A. Ioanid and C. Scarlat, "Neuromarketing Tools in Industry 4.0 Context: A Study on the Romanian Market," in *The 15th International Conference Interdisciplinarity in Engineering*, 2022, pp. 370–381.
- [134] J. Villalba-Diez, X. Zheng, D. Schmidt, and M. Molina, "Characterization of Industry 4.0 Lean Management Problem-Solving Behavioral Patterns Using EEG Sensors and Deep Learning," *Sensors*, vol. 19, no. 13, p. 2841, Jun. 2019, doi: 10.3390/s19132841.
- [135] K. D. Tzimourta *et al.*, "Analysis of electroencephalographic signals complexity regarding Alzheimer's Disease," *Comput. Electr. Eng.*, vol. 76, pp. 198–212, Jun. 2019, doi: 10.1016/j.compeleceng.2019.03.018.
- [136] L. M. Peñuela Calderón and N. E. Caicedo Gutierrez, "Detección de dolor a partir de señales de EEG," *Rev. EIA*, vol. 19, no. 38, Jun. 2022, doi: 10.24050/reia.v19i38.1577.
- [137] R. A. Ramadan and A. V. Vasilakos, "Brain computer interface: control signals review," *Neurocomputing*, vol. 223, pp. 26–44, Feb. 2017, doi: 10.1016/j.neucom.2016.10.024.
- [138] S. Saha *et al.*, "Progress in Brain Computer Interface: Challenges and Opportunities," *Front. Syst. Neurosci.*, vol. 15, Feb. 2021, doi: 10.3389/fnsys.2021.578875.
- [139] L. M. Alonso-Valerdi, M. A. Arreola-Villarruel, and J. Argüello-García, "Interfaces Cerebro-Computadora: Conceptualización, Retos de Rediseño e Impacto Social," *Rev. Mex. Ing. Biomed.*, vol. 40, no. 3, Sep. 2019, doi: 10.17488/RMIB.40.3.8.

- [140] S. FERNANDEZ FRAGA and J. RANGEL MONDRAGON, “Comparativo de los Algoritmos de Dimensión Fractal Higuchi, Katz y Multiresolución de Conteo de Cajas en Señales EEG Basadas en Potenciales Relacionados por Eventos,” *Rev. EIA*, vol. 14, no. 27, pp. 73–83, Sep. 2017, doi: 10.24050/reia.v14i27.864.
- [141] S. K. Mudgal, S. K. Sharma, J. Chaturvedi, and A. Sharma, “Brain computer interface advancement in neurosciences: Applications and issues,” *Interdisciplinary Neurosurgery: Advanced Techniques and Case Management*, vol. 20. 2020, doi: 10.1016/j.inat.2020.100694.
- [142] I. Moreno *et al.*, “Los sistemas de interfaz cerebro-computadora basado en EEG: características y aplicaciones,” *I+D Tecnológico*, vol. 15, no. 2, pp. 13–26, Jul. 2019, doi: 10.33412/idt.v15.2.2230.
- [143] R. Hornero, R. Corralejo, and D. Álvarez, “Brain-Computer Interface (bCI) aplicado al entrenamiento cognitivo y control domótico para prevenir los efectos del envejecimiento.” Accessed: Oct. 24, 2022. [Online]. Available: <http://www.gib.tel.uva.es/>.
- [144] A. Monasterio Astobiza, T. Ausín, M. Toboso, R. Morte Ferrer, M. Aparicio Payá, and D. López, “Traducir el pensamiento en acción: Interfaces cerebro-máquina y el problema ético de la agencia,” *Rev. bioética y derecho*, vol. 46, pp. 29–46, 2019, [Online]. Available: www.bioeticayderecho.ub.edu.
- [145] O. Piña Ramírez, “Pantallas escenario: implementación y evaluación de una variante del deletreador P300 con imágenes de fondo y marcadores de estimulación asimétricamente acomodados,” Universidad Autónoma Metropolitana, Unidad Iztapalapa, Ciudad de México, 2018.
- [146] L. Sauer, L. Valero, F. Velasco-Álvarez, and R. Ron-Angevin, “Psychological variables in the control of brain-computer interfaces,” *Psicothema*, vol. 23, pp. 745–751, Nov. 2011, Accessed: Oct. 27, 2022. [Online]. Available: https://www.researchgate.net/publication/51764886_Psychological_variables_in_the_control_of_brain-computer_interfaces.
- [147] L. A. Moctezuma Pascual, “Distinción de estados de actividad e inactividad lingüística para interfaces cerebro computadora,” Benemérita Universidad Autónoma de Puebla, Puebla, 2017.
- [148] A. Bashashati, M. Fatourehchi, R. K. Ward, and G. E. Birch, “A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals,” *J. Neural Eng.*, vol. 4, no. 2, pp. R32–R57, Jun. 2007, doi: 10.1088/1741-2560/4/2/R03.
- [149] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, “Brain-computer interfaces for communication and control,” *Clin. Neurophysiol.*, vol. 113, no. 6, pp. 767–791, Jun. 2002, doi: 10.1016/S1388-2457(02)00057-3.

- [150] A. A. Torres-García, C. A. Reyes-García, L. Villaseñor-Pineda, and J. M. Ramírez-Cortés, “Análisis de señales electroencefalográficas para la clasificación de habla imaginada,” *Rev. Mex. Ing. biomédica*, vol. 34, no. 1, pp. 23–39, 2013, [Online]. Available: http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0188-95322013000100002.
- [151] A. E. Gallegos Acosta, M. D. Torres Soto, A. Torres Soto, and E. E. Ponce de León Sentí, “Contrastación de algoritmos de aprendizaje automático para la clasificación de señales EEG,” *Res. Comput. Sci.*, vol. 148, no. 8, pp. 515–525, 2020.
- [152] A. Kawala-Sterniuk *et al.*, “Summary of over fifty years with brain-computer interfaces—a review,” *Brain Sciences*, vol. 11, no. 1. 2021, doi: 10.3390/brainsci11010043.
- [153] I. Moreno *et al.*, “Los sistemas de interfaz cerebro-computadora basado en EEG: características y aplicaciones,” *I+D Tecnológico*, vol. 15, no. 2, pp. 13–26, Jul. 2019, doi: 10.33412/idt.v15.2.2230.
- [154] N. Tibrewal, N. Leeuwis, and M. Alimardani, “Classification of motor imagery EEG using deep learning increases performance in inefficient BCI users,” *PLoS One*, vol. 17, no. 7, p. e0268880, Jul. 2022, doi: 10.1371/journal.pone.0268880.
- [155] J. A. Carrasco Ochoa and J. F. Martínez Trinidad, “Reconocimiento de Patrones,” *Komputer Sapiens, Revista de Divulgación de la Sociedad Mexicana de Inteligencia Artificial*, vol. 3. SMIA, México NV - 2, pp. 5–10, 2011, Accessed: Aug. 02, 2022. [Online]. Available: https://d1wqtxts1xzle7.cloudfront.net/30778872/ks32_1.6MB_compacta-with-cover-page-v2.pdf?Expires=1659469931&Signature=ZCDVXVcKW7QcTyt1lwmCzNU1rjUWBPFYkODokQmjNWzBIZRjk8KOi7jiXq4lcog9tSEjOb0jgxSMJkwhISDbac2jk~d13D-DWTD5gJPbKP3tjzLV7zvw~z~GmjxCpupiYw8SZMWmnCOE4ntS27Oum13L7ZDQEA3~EJT2rFls6STMsEt2VpM6pMkv2a-ZPzPzGmiklxgwFrx6NaIOAFb6bdT3Vb-Cmb3UKc9leYZ2IKTqjQXDHnpvobZUnp~FiFn55LpQXNYXlgrZEcujmqtHu4CrSd6iAVuBf~LuoKOGbM0VPZstuRGXv7wV54sOLfe1s6Gn3L23seTBaxcCg__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA#page=7.
- [156] H. Vega Huerta, A. Cortez Vasquez, A. Maria Huayna, L. Alarcon Loayza, and P. Romero Naupari, “Reconocimiento de patrones mediante redes neuronales artificiales.(Report),” *Rev. Investig. Sist. e Inform.*, vol. 6, no. 2, p. 17, 2009.
- [157] A. E. Gallegos Acosta, F. J. Álvarez Rodríguez, M. D. Torres Soto, and A. Torres Soto, “Identificación de factores de riesgo en patologías médicas

mediante métodos de selección de subconjuntos de características [recurso electrónico],” Universidad Autónoma de Aguascalientes, Aguascalientes, México, 2018.

- [158] Y. Anzai, *Pattern Recognition and Machine Learning*, 1st ed., vol. 1. San Diego: Academic Press, Inc, 1992.
- [159] X. Y. Zhang, C. L. Liu, and C. Y. Suen, “Towards Robust Pattern Recognition: A Review,” *Proceedings of the IEEE*, vol. 108, no. 6. Institute of Electrical and Electronics Engineers Inc., pp. 894–922, Jun. 01, 2020, doi: 10.1109/JPROC.2020.2989782.
- [160] D. De Ridder, J. De Ridder, and M. J. T. Reinders, “Pattern recognition in bioinformatics,” *Brief. Bioinform.*, vol. 14, no. 5, 2013, doi: 10.1093/bib/bbt020.
- [161] N. M, “A Comprehensive Overview of Clustering Algorithms in Pattern Recognition,” *IOSR J. Comput. Eng.*, vol. 4, no. 6, pp. 23–30, 2012, doi: 10.9790/0661-0462330.
- [162] X. Huang, L. Wu, and Y. Ye, “A Review on Dimensionality Reduction Techniques,” *Int. J. Pattern Recognit. Artif. Intell.*, vol. 33, no. 10, 2019, doi: 10.1142/S0218001419500174.
- [163] F. A. Sánchez Garfias, J. L. Díaz de León Santiago, and C. Yáñez Márquez, “Reconocimiento automático de patrones: conceptos básicos,” vol. 10. Research in Computer Science, México, pp. 91–102, 2003, [Online]. Available: <http://www.alfabeta.org.mx/RecPat.htm>.
- [164] A. Fernández, “Selección de Características - Reconocimiento de Patrones 2013.” Universidad de la República de Uruguay, Uruguay, 2013.
- [165] A. R. Webb, *Statistical Pattern Recognition*, 2nd ed., vol. 1. England: John Wiley & Sons, 2002.
- [166] A. K. Jain, P. W. Duin, and Jianchang Mao, “Statistical pattern recognition: a review,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 22, no. 1, pp. 4–37, 2000, doi: 10.1109/34.824819.
- [167] H. BUNKE, “STRUCTURAL AND SYNTACTIC PATTERN RECOGNITION,” in *Handbook of Pattern Recognition and Computer Vision*, WORLD SCIENTIFIC, 1993, pp. 163–209.
- [168] K. S. Fu, “Syntactic Approach to Pattern Recognition,” in *Spoken Language Generation and Understanding*, Dordrecht: Springer Netherlands, 1980, pp. 221–251.
- [169] Y. M. Al-Sharo, A. T. Abu-Jassar, S. Sotnik, and V. Lyashenko, “Neural Networks As A Tool For Pattern Recognition of Fasteners,” *Int. J. Eng. Trends Technol.*, vol. 69, no. 10, pp. 151–160, Oct. 2021, doi: 10.14445/22315381/IJETT-V69I10P219.

- [170] N. Escudero, “Reconocimiento de patrones bajo el enfoque lógico combinatorio,” Universidad de Panamá, Panamá, 2021.
- [171] L. E. Quintos Vázquez, “Reconocimiento de Patrones, el enfoque Lógico Combinatorio,” Instituto Politécnico Nacional, 2009.
- [172] B. Bajic, I. Cosic, M. Lazarevic, N. Sremčev, and A. Rikalovic, *Machine Learning Techniques for Smart Manufacturing: Applications and Challenges in Industry 4.0*. 2018.
- [173] A. A. A. Elhag, “High-Dimensional Learning,” *Towards Data Science*, Feb. 06, 2022. <https://towardsdatascience.com/high-dimensional-learning-ea6131785802> (accessed Jul. 10, 2022).
- [174] I. H. Sarker, “Machine Learning: Algorithms, Real-World Applications and Research Directions,” *SN Comput. Sci.*, vol. 2, no. 3, p. 160, May 2021, doi: 10.1007/s42979-021-00592-x.
- [175] Y. Santiesteban Alganza and A. Pons Porrata, “Lex: Un nuevo algoritmo para el calculo de los testores tipicos,” *Ciencias Mat.*, vol. 21, no. 1, Jan. 2003, [Online]. Available: <https://dibpxy.uaa.mx/login?url=http://search.ebscohost.com/login.aspx?direct=true&db=edsgii&AN=edsgcl.147016161&lang=es&site=eds-live&scope=site>.
- [176] A. Pereira González, “Selección de Características para el Reconocimiento de Patrones con Datos de Alta Dimensionalidad en Fusión Nuclear.” Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas (CIEMAT), España, 2015, [Online]. Available: <http://www-fusion.ciemat.es/PhDThesis/Pereira.pdf>.
- [177] J. Li *et al.*, “Feature Selection: A Data Perspective,” *ACM Comput. Surv.*, vol. 50, no. 6, pp. 1–45, 2017, doi: 10.1145/3136625.
- [178] U. M. Khaire and R. Dhanalakshmi, “Stability of feature selection algorithm: A review,” *Journal of King Saud University - Computer and Information Sciences*, vol. 34, no. 4. 2022, doi: 10.1016/j.jksuci.2019.06.012.
- [179] N. Martínez, M. León, and Z. García, “Features Selection Through FS-Testors in Case-Based Systems of Teaching-Learning,” in *MICA I 2007: Advances in Artificial Intelligence*, 2007, pp. 1206–1217.
- [180] I. Mejía-Guevara and A. Kuri, *Evolutionary Feature and Parameter Selection in Support Vector Regression*, vol. 4827. 2007.
- [181] Y. Villuendas Rey, *Esquema para el pre-procesamiento de conjuntos de entrenamiento de clasificadores del vecino más cercano basado en extensiones a la teoría de los conjuntos aproximados*. Havana, CUBA: Editorial Universitaria, 2014.

- [182] E. Alba Cabrera, R. Santana, A. Ochoa Rodríguez, and M. Lazo Cortés, "Finding Typical Testors By Using An Evolutionary Strategy," *Proc. 5th Ibero Am. Symp. Pattern Recognit.*, pp. 267–278, 2000.
- [183] J. P. Gómez, F. E. H. Montero, J. C. Sotelo, J. C. G. Mancilla, and Y. V Rey, "RoPM: An Algorithm for Computing Typical Testors Based on Recursive Reductions of the Basic Matrix," *IEEE Access*, vol. 9, pp. 128220–128232, 2021, doi: 10.1109/ACCESS.2021.3112385.
- [184] V. I. González-Guevara, S. Godoy-Calderon, E. Alba-Cabrera, and J. Ibarra-Fiallo, "A Mixed Learning Strategy for Finding Typical Testors in Large Datasets," *Prog. Pattern Recognition, Image Anal. Comput. Vision, Appl. CIARP 2015. Lect. Notes Comput. Sci.*, vol. 9423, pp. 716–723, 2015, doi: 10.1007/978-3-319-25751-8_86.
- [185] A. Lias-Rodríguez and A. Pons-Porrata, "Un nuevo Algoritmo de Escala Exterior para el Cálculo de los Testores Típicos." Centro de Estudios de Reconocimiento de Patrones y Minería de Datos, Santiago de Cuba, Cuba, p. 10, 2005, [Online]. Available: http://www.cerpamid.co.cu/sitio/files/publicaciones/1034921953BR_REC PAT 09.pdf.
- [186] V. Rodríguez-Diez, J. F. Martínez-Trinidad, J. A. Carrasco-Ochoa, and M. S. Lazo-Cortés, "The Impact of Basic Matrix Dimension on the Performance of Algorithms for Computing Typical Testors," in *Pattern Recognition*, 2018, pp. 41–50.
- [187] M. D. Torres Soto, A. Torres Soto, M. de la L. Torres Soto, L. Bermudez Rosales, and E. E. Ponce de León Sentí, "Factores Predisponentes en Relajación Residual Neuromuscular," *Research in Computing Science*, vol. 93. Instituto Politécnico Nacional, pp. 163–174, 2015, [Online]. Available: http://www.rcs.cic.ipn.mx/2015_93/.
- [188] J. Ochoa Somuano, "Técnicas de Selección de Atributos para la Categorización Automática de Escenas Visuales," Centro Nacional de Investigación y Desarrollo Tecnológico, Cuernavaca, Morelos, 2005.
- [189] J. Ruíz Shucloper, E. Alba Cabrera, and M. Lazo Cortés, "Introducción a la Teoría de Testores." Departamento de Ingeniería Electrica, CINVESTAV-IPN, p. 197, 1995.
- [190] M. D. Torres, E. Ponce de León, C. A. Ochoa, A. Torres, and E. Díaz, "Mecanismos de Aceleración en Selección de Características Basada en el Peso Informacional de las Variables para Aprendizaje no Supervisado," *Revista Iberoamericana de Sistemas, Cibernética e Informática*, vol. 6. Revista Iberoamericana de Sistemas, Cibernética e Informática, pp. 29–34, 2009.
- [191] R. A. Vázquez and S. Godoy-Calderón, "Using Testor Theory to Reduce the

- Dimension of Neural Network Models,” *Res. Comput. Sci.*, vol. 28, pp. 93–103, 2007.
- [192] G. Díaz Sánchez *et al.*, “Typical Testors Generation Based on an Evolutionary Algorithm,” *Intell. Data Eng. Autom. Learn. - IDEAL 2011*, vol. 6936, Sep. 2011, doi: 10.1007/978-3-642-23878-9.
- [193] J. A. Santos, A. Carrasco, and J. F. Martínez, “Feature Selection using Typical Testors applied to Estimation of Stellar Parameters,” *Computación y Sistemas*, vol. 8. Instituto Politécnico Nacional, México, pp. 15–23, 2004.
- [194] M. O. Cotilla, “Un Recorrido por la Sismología de Cuba.” Editorial Complutense, S. A., Cuba, 2006, [Online]. Available: <https://books.google.com.mx/books?id=OqXDI5wm5GUC&lpg=PT100&ots=8EAFIZR-uM&dq=peso+informacional+testores&pg=PT100#v=onepage&q=peso+informacional+testores&f=false>.
- [195] R. M. Cunqueiro, “Algoritmos heurísticos en optimización combinatoria,” *Val. Universidad Val. Retrieved*, vol. 11, no. 01, p. 2012, 2003.
- [196] O. Suarez, “Una Aproximación a la Heurística y Metaheurísticas,” *Tendencias en la Ing.*, vol. 1, no. 2, pp. 44–51, 2011.
- [197] J. M. Chaves González, “Metaheurísticas y Computación Paralela para el Problema de la Planificación de Frecuencias en Redes Reales de Telecomunicaciones,” Universidad de Extremadura, Cáseres, España, 2011.
- [198] A. Duarte Muñoz, *Metaheurísticas*. España: Dykinson, 2008.
- [199] S. H. Zanakis and J. R. Evans, “HEURISTIC ‘OPTIMIZATION’: WHY, WHEN, AND HOW TO USE IT,” *Interfaces (Providence)*, vol. 11, no. 5, pp. 84–91, 1981, [Online]. Available: [http://search.ebscohost.com/login.aspx?direct=true&db=bth&AN=6691071\(=es&site=ehost-live&scope=site](http://search.ebscohost.com/login.aspx?direct=true&db=bth&AN=6691071(=es&site=ehost-live&scope=site).
- [200] S. Alonso, O. Córdón, I. Fernandez de Viana, and F. Herrera, “La Metaheurística de Optimización Basada en Colonia de Hormigas: Modelos y Nuevos Enfoques,” *Mejora de Metaheurísticas mediante Hibridación y sus Aplicaciones*. Universidad de Granada, Granada, España, pp. 1–49, 2003, [Online]. Available: [http://sci2s.ugr.es/sites/default/files/files/Teaching/OtherPostGraduateCourses/MasterEstructuras/bibliografia/La Metaheuristica de OCH - Modelos y Nuevos Enfoques.pdf](http://sci2s.ugr.es/sites/default/files/files/Teaching/OtherPostGraduateCourses/MasterEstructuras/bibliografia/La+Metaheuristica+de+OCH+-+Modelos+y+Nuevos+Enfoques.pdf).
- [201] Z. Michalewicz and D. Fogel, “How to Solve It: Modern Heuristics.” Springer, Berlin, Alemania, 2004.
- [202] Á. García Sánchez, “Técnicas metahurísticas,” *U. D. de Organización de la Producción*. Universidad Politécnica de Madrid, Madrid, p. 47, [Online]. Available: <http://www.iol.etsii.upm.es/>.

- [203] P. Rodríguez-Piñero Tolmos, "Introducción a los Algoritmos Genéticos y sus Aplicaciones." Asociación Española de Profesores Universitarios de Matemáticas para la Economía y la Empresa, Paseo de los Artilleros s/n Madrid 28032, pp. 1–9, 2002, [Online]. Available: <https://pdfs.semanticscholar.org/887a/7c78eedd980993c467abe0dbcc79dec26937.pdf>.
- [204] P. Linardatos, V. Papastefanopoulos, and S. Kotsiantis, "Explainable ai: A review of machine learning interpretability methods," *Entropy*, vol. 23, no. 1. 2021, doi: 10.3390/e23010018.
- [205] R. Roscher, B. Bohn, M. F. Duarte, and J. Garcke, "Explainable Machine Learning for Scientific Insights and Discoveries," *IEEE Access*, vol. 8, 2020, doi: 10.1109/ACCESS.2020.2976199.
- [206] C. Janiesch, P. Zschech, and K. Heinrich, "Machine learning and deep learning," *Electron. Mark.*, vol. 31, no. 3, pp. 685–695, Sep. 2021, doi: 10.1007/s12525-021-00475-2.
- [207] A. T. Norman, *Aprendizaje Automático en Acción*, 1st ed. TekTime, 2019.
- [208] F. Sancho Caparrini, "Introducción al aprendizaje automático," Sevilla, España, 2017. Accessed: Jun. 21, 2019. [Online]. Available: <http://www.cs.us.es/~fsancho/?e=75>.
- [209] C. Soto Valero, "Aplicación de métodos de aprendizaje automático en el análisis y la predicción de resultados deportivos," *Retos: nuevas tendencias en educación física, deporte y recreación*, vol. 34, pp. 377–382, 2018.
- [210] T. M. Mitchell, *Machine Learning*, 1st ed. McGraw-Hill/Engineering/Math, 1997.
- [211] I. El Naqa, R. Li, and M. J. Murphy, *Machine Learning in Radiation Oncology*. Cham: Springer International Publishing, 2015.
- [212] I. El Naqa and M. J. Murphy, "What Is Machine Learning?," in *Machine Learning in Radiation Oncology*, Cham: Springer International Publishing, 2015, pp. 3–11.
- [213] A. V Joshi, "Introduction to AI and ML," in *Machine Learning and Artificial Intelligence*, Cham: Springer International Publishing, 2020, pp. 3–7.
- [214] Q. Zhang, K. Barri, P. Jiao, H. Salehi, and A. H. Alavi, "Genetic programming in civil engineering: advent, applications and future trends," *Artif. Intell. Rev.*, vol. 54, no. 3, pp. 1863–1885, Mar. 2021, doi: 10.1007/s10462-020-09894-7.
- [215] S. Raschka, J. Patterson, and C. Nolet, "Machine learning in python: Main developments and technology trends in data science, machine learning, and artificial intelligence," *Information (Switzerland)*, vol. 11, no. 4. 2020, doi: 10.3390/info11040193.

- [216] B. Mehlig, *Machine Learning with Neural Networks*. 2021.
- [217] F. Chollet, *Deep Learning with Python*. Shelter Island: Manning Publications Co., 2018.
- [218] R. Y. Choi, A. S. Coyner, J. Kalpathy-Cramer, M. F. Chiang, and J. P. Campbell, "Introduction to Machine Learning, Neural Networks, and Deep Learning," *Transl. Vis. Sci. Technol.*, vol. 9, no. 14, pp. 1–11, Feb. 2020, doi: <https://doi.org/10.1167/tvst.9.2.14>.
- [219] A. Moreno *et al.*, *Aprendizaje automático*. Cataluña, España: Ediciones UPC, 1994.
- [220] F. Sancho Caparrini, "Aprendizaje inductivo: árboles de decisión," *Aprendizaje inductivo: árboles de decisión*, 2018. <http://www.cs.us.es/~fsancho/?e=104> (accessed May 18, 2020).
- [221] P. Priore, D. De la Fuente, R. Pino, and J. Puente, "Utilización de aprendizaje inductivo en la toma de decisiones. Aplicación de un problema de secuenciación," *Investig. Eur. Dir. y Econ. la Empres.*, vol. 10, no. 3, pp. 17–36, 2004.
- [222] A. Bradford, "Deductive Reasoning vs. Inductive Reasoning," *livescience.com*, 2017. <https://www.livescience.com/21569-deduction-vs-induction.html> (accessed Nov. 20, 2019).
- [223] C. M. Carroll, "Deductive reasoning.," *Salem Press Encyclopedia of Health*. 2019, [Online]. Available: <http://search.ebscohost.com/login.aspx?direct=true&db=ers&AN=93871880&site=eds-live>.
- [224] C. García Cambronero and I. Gómez Moreno, "Algoritmos de aprendizaje: kNN y Kmeans," Madrid, España, 2006. [Online]. Available: <http://www.it.uc3m.es/~jvillena/irc/practicas/08-09/06.pdf>.
- [225] M. Cardenas, R. Medel, J. Castillo, J. C. Vázquez, and O. Casco, "Modelos de Aprendizaje Supervisados: aplicaciones para la predicción de incendios forestales en la provincia de Córdoba," 2015. [Online]. Available: <http://sedici.unlp.edu.ar/handle/10915/45467>.
- [226] A. V Joshi, *Machine Learning and Artificial Intelligence*, vol. 1. Cham: Springer International Publishing, 2020.
- [227] Á. Gonzalo, "Tipos de aprendizaje automático," *Machine Learning para todos*, 2018. <http://machinelearningparatodos.com/tipos-de-aprendizaje-automatico/> (accessed Jun. 22, 2019).
- [228] A. Jeffares, "Supervised vs Unsupervised Learning in 3 Minutes," *Towards Data Science*, Jul. 24, 2018. <https://towardsdatascience.com/supervised-vs-unsupervised-learning-in-2-minutes-72dad148f242> (accessed Nov. 09, 2022).

- [229] J. Martínez Heras, “¿Clasificación o Regresión?,” *IArtificial.net*, 2020. <https://www.iartificial.net/clasificacion-o-regresion/> (accessed Sep. 28, 2020).
- [230] L. González, “Diferencia entre algoritmos de clasificación y regresión,” *Aprende todo sobre inteligencia artificial*, Jun. 22, 2018. <https://ligdigonzalez.com/diferencia-entre-algoritmos-de-clasificacion-y-regresion/> (accessed Sep. 28, 2020).
- [231] I. Moral Peláez, “Modelos de regresión lineal simple y regresión logística,” *SEDEN*, pp. 195–214, 2016, [Online]. Available: [https://www.revistaseden.org/files/14-cap 14.pdf](https://www.revistaseden.org/files/14-cap%2014.pdf).
- [232] R. Baeza-Serrato and J. Antonio Vázquez-López, “Transición de un modelo de regresión lineal múltiple predictivo, a un modelo de regresión no lineal simple explicativo con mejor nivel de predicción: Un enfoque de dinámica de sistemas Transition from a predictive multiple linear regression model to an explanatory simple nonlinear regression model with higher level of prediction: A systems dynamics approach,” *Fac. Ing. Univ. Antioquia*, no. 71, pp. 59–71, 2014, [Online]. Available: http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0120-62302014000200007&lng=en&nrm=iso&tlng=es.
- [233] L. Orellana, “Análisis de regresión.” Departamento de Matemáticas, Facultad de Ciencias Exactas y Naturales, Universidad de Buenos Aires, Buenos Aires, Argentina, pp. 1–49, 2008, [Online]. Available: [http://www.dm.uba.ar/materias/estadistica_Q/2011/1/clase regresion simple.pdf](http://www.dm.uba.ar/materias/estadistica_Q/2011/1/clase%20regresion%20simple.pdf).
- [234] D. Montgomery, E. Peck, G. Vining, and V. González Pozo, *Introducción al análisis de regresión lineal*, 3rd ed. Editorial Patria, 2003.
- [235] D. Rodríguez, “Diferencias entre regresión y clasificación en aprendizaje automático,” *Analytics Lane*, Nov. 26, 2018. <https://www.analyticslane.com/2018/11/26/diferencias-entre-regresion-y-clasificacion-en-aprendizaje-automatico/> (accessed Sep. 28, 2020).
- [236] V. Romann, “Aprendizaje Supervisado: Introducción a la Clasificación y Principales Algoritmos,” *Ciencia y Datos*, May 27, 2019. <https://medium.com/datos-y-ciencia/aprendizaje-supervisado-introducción-a-la-clasificación-y-principales-algoritmos-dadee99c9407> (accessed Sep. 28, 2020).
- [237] Amazon Web Services, *Amazon Machine Learning: Guía para desarrolladores*. Amazon Web Services.
- [238] A. M. Padilla-Ospina, J. E. Medina-Vásquez, and J. H. Ospina-Holguín, “Métodos de aprendizaje automático en los estudios prospectivos desde un ejemplo de la financiación de la innovación en Colombia,” *Rev. Investig. Desarro. e Innovación*, vol. 11, no. 1, pp. 9–21, Aug. 2020, doi:

10.19053/20278306.v11.n1.2020.11676.

- [239] F. Sancho Caparrini, “Clasificación supervisada y no supervisada,” *Univerisdad de sevilla*, 2018. <http://www.cs.us.es/~fsancho/?e=77> (accessed Jun. 22, 2019).
- [240] P. Recuerdo de los Santos, “Machine Learning a tu alcance: La matriz de confusión,” *Think Big/Empresas*, 2018. <https://empresas.blogthinkbig.com/ml-a-tu-alcance-matriz-confusion/> (accessed Jun. 22, 2019).
- [241] K. Pina, “Matriz de confusión,” *koldopina*, 2018. <https://koldopina.com/matriz-de-confusion/> (accessed Jun. 22, 2019).
- [242] C. Malagón Luque, “Clasificadores bayesianos. El algoritmo Naïve Bayes,” Madrid, 2003. [Online]. Available: https://www.nebrija.es/~cmalagon/inco/Apuntes/bayesian_learning.pdf.
- [243] G. Gutiérrez Esparza, L. Margain Fuentes, J. Canul Reich, and T. A. Ramírez del Real, “Un modelo basado en el Clasificador Naïve Bayes para la evaluación del desempeño docente,” *RIED. Rev. Iberoam. Educ. a Distancia*, vol. 20, no. 2, p. 293, May 2017, doi: 10.5944/ried.20.2.17717.
- [244] B. Sierra Araujo, *Aprendizaje automático : conceptos básicos y avanzados : aspectos prácticos utilizando el software Weka / coordinador Basilio Sierra Araujo*. 2006.
- [245] L. E. Sucar, *Aprendizaje Automático: conceptos básicos y avanzados*. Tonantzintla, Puebla: Instituto Nacional de Astrofísica, Óptica y Electrónica, 2006.
- [246] J. Abellán and J. G. Castellano, “Improving the Naive Bayes classifier via a quick variable selection method using maximum of entropy,” *Entropy*, vol. 19, no. 6, Jun. 2017, doi: 10.3390/e19060247.
- [247] F. Rozo-García, “Revisión de las tecnologías presentes en la industria 4.0,” *Rev. UIS Ing.*, vol. 19, no. 2, pp. 177–191, May 2020, doi: 10.18273/revuin.v19n2-2020019.
- [248] G. R. Yang and X.-J. Wang, “Artificial Neural Networks for Neuroscientists: A Primer,” *Neuron*, vol. 107, no. 6, pp. 1048–1070, 2020, doi: <https://doi.org/10.1016/j.neuron.2020.09.005>.
- [249] O. I. Abiodun, A. Jantan, A. E. Omolara, K. V. Dada, N. A. Mohamed, and H. Arshad, “State-of-the-art in artificial neural network applications: A survey,” *Heliyon*, vol. 4, no. 11, p. e00938, 2018, doi: <https://doi.org/10.1016/j.heliyon.2018.e00938>.
- [250] J. Ribeiro, R. Lima, T. Eckhardt, and S. Paiva, “Robotic Process Automation and Artificial Intelligence in Industry 4.0 – A Literature review,” *Procedia Comput. Sci.*, vol. 181, pp. 51–58, 2021, doi: 10.1016/j.procs.2021.01.104.

- [251] C. A. Guillaizaca González and V. Hernandez A., “Clasificador de Productos Agrícolas para Control de Calidad basado en Machine Learning e Industria 4.0,” *Rev. Perspect.*, vol. 2, no. 2, pp. 21–28, Jul. 2020, doi: 10.47187/perspectivas.vol2iss2.pp21-28.2020.
- [252] J. M. Peña Lorenzo, “Aplicación de técnicas de aprendizaje profundo (deep learning) para la detección de objetos en industria 4.0,” Universidad de Valladolid, Valladolid, 2020.
- [253] N. V. Ramírez Pérez, M. Laguna Estrada, and N. N. Rubín Ramírez, “UN ACERCAMIENTO A LA INDUSTRIA 4.0 A TRAVÉS DE REDES NEURONALES PARA LA REDUCCIÓN DE SCRAP EN UNA EMPRESA AUTOMOTRÍZ,” *Pist. Educ.*, vol. 41, no. 133, pp. 551–568, Dec. 2019, Accessed: Jul. 11, 2022. [Online]. Available: <http://www.itc.mx/ojs/index.php/pistas/article/view/2144>.
- [254] F. Villada, N. Muñoz, and E. García-Quintero, “Redes neuronales artificiales aplicadas a la predicción del precio del oro,” in *Informacion Tecnologica*, 2016, vol. 27, no. 5, pp. 143–150, doi: 10.4067/S0718-07642016000500016.
- [255] W. Rivas-Asanza, B. Mazon-Olivo, and F. Mejia, “Capítulo 1: Generalidades de las redes neuronales artificiales,” in *Redes Neuronales Artificiales Aplicadas al Reconocimiento de Patrones*, 2018, pp. 11–35.
- [256] O. I. Abiodun *et al.*, “Comprehensive Review of Artificial Neural Network Applications to Pattern Recognition,” *IEEE Access*, vol. 7, pp. 158820–158846, 2019, doi: 10.1109/ACCESS.2019.2945545.
- [257] I. A. Basheer and M. Hajmeer, “Artificial neural networks: fundamentals, computing, design, and application,” *J. Microbiol. Methods*, vol. 43, no. 1, pp. 3–31, 2000, doi: [https://doi.org/10.1016/S0167-7012\(00\)00201-3](https://doi.org/10.1016/S0167-7012(00)00201-3).
- [258] D. J. Matich, “Cátedra: Informática Aplicada a la Ingeniería de Procesos-Orientación I Redes Neuronales: Conceptos Básicos y Aplicaciones,” México, 2001. [Online]. Available: https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monograias/matich-redesneuronales.pdf.
- [259] M. Geisslinger, “Autonomous Driving: Object Detection using Neural Networks for Radar and Camera Sensor Fusion,” Technical University of Munich, Munich, 2019.
- [260] F. Sancho Caparrini, “Redes Neuronales: una visión superficial,” <http://www.cs.us.es/>, 2018. <http://www.cs.us.es/~fsancho/?e=72> (accessed Jun. 25, 2019).
- [261] M. L. Dering and C. S. Tucker, “A Convolutional Neural Network Model for Predicting a Product’s Function, Given Its Form,” *J. Mech. Des.*, vol. 139, no. 11, p. 111408, Oct. 2017, doi: 10.1115/1.4037309.

- [262] R. Salas, “Redes Neuronales Artificiales,” Chile, 2004.
- [263] F. Amato, A. López, E. M. Peña-Méndez, P. Vañhara, A. Hampf, and J. Havel, “Artificial neural networks in medical diagnosis,” *Journal of Applied Biomedicine*, vol. 11, no. 2. 2013, doi: 10.2478/v10136-012-0031-x.
- [264] S. Parra and M. Torrens, *La Inteligencia Artificial: el camino hacia la ultrainteligencia*. Barcelona: RBA Coleccionables, 2017.
- [265] D. Ravi *et al.*, “Deep Learning for Health Informatics,” *IEEE J. Biomed. Heal. Informatics*, vol. 21, no. 1, pp. 4–21, Jan. 2017, doi: 10.1109/JBHI.2016.2636665.
- [266] C. Cao *et al.*, “Deep Learning and Its Applications in Biomedicine,” *Genomics, Proteomics and Bioinformatics*, vol. 16, no. 1. 2018, doi: 10.1016/j.gpb.2017.07.003.
- [267] J. M. Ede, “Deep learning in electron microscopy,” *Machine Learning: Science and Technology*, vol. 2, no. 1. 2021, doi: 10.1088/2632-2153/abd614.
- [268] R. González, A. Barrientos, M. Toapanta, and J. Del Cerro, “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.*, vol. 14, no. 4, pp. 394–405, Oct. 2017, doi: 10.1016/j.riai.2017.07.005.
- [269] E. Carmona, *Tutorial sobre Máquinas de Vectores Soporte (SVM)*. Madrid, 2016.
- [270] S. A. Maldonado Alarcón, “Modelos de selección de atributos para support vector machines,” Universidad de Chile, Santiago de Chile, 2011.
- [271] L. Salamanca Polo, “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.
- [272] J. Vargas, B. Conde, V. Paccapelo, and L. Zingaretti, “MÁQUINAS DE SOPORTE VECTORIAL: METODOLOGÍA Y APLICACIÓN EN R.” [Online]. Available: <https://www.actinver.com/cs/Actinver/Espanol/Privado/Emisiones/265-231-1-SP.pdf>.
- [273] A. Flores, S. Maldonado, and R. Weber, “Selección de atributos y support vector machines adaptado al problema de fuga de clientes´Alvaro,” *Revista Ingeniería de Sistemas*, pp. 87–109, 2015.
- [274] P. H. Winston, “Lecture 16: Learning: Support Vector Machines.” Massachusetts Institute of Technology, Boston, 2010, [Online]. Available: https://www.youtube.com/watch?v=_PwhiWxHK8o.
- [275] G. Betancourt, “Las Máquinas de Soporte Vectorial (SVMs),” *Sci. Tech.*, no. 27, 2005, [Online]. Available:

<http://revistas.utp.edu.co/index.php/revistaciencia/article/view/6895/4139>.

- [276] S. Maldonado and R. Weber, "Modelos de Selección de Atributos para Support Vector Machines," *Rev. Ing. Sist.*, vol. 26, pp. 49–70, 2012, [Online]. Available: https://d1wqtxts1xzle7.cloudfront.net/30817678/maldonado1.pdf?1362361853=&response-content-disposition=inline%3B+filename%3DModelos_de_Seleccion_de_Atributos_para_S.pdf&Expires=1593100227&Signature=cl79qiE-wzWXD7SgXyB8krogcU367AY9Mnde3T0aNVOiy7fZbNe0-UwXd.
- [277] J. A. Rodrigo, "Máquinas de Vector Soporte (Support Vector Machines, SVMs)," *cienciadedatos.net*, 2017. https://www.cienciadedatos.net/documentos/34_maquinas_de_vector_soporte_e_support_vector_machines (accessed Jun. 27, 2020).
- [278] N. Sánchez Anzola, "Máquinas de soporte vectorial y redes neuronales artificiales en la predicción del movimiento USD/COP spot intradiario," *ODEON*, no. 9, p. 113, Feb. 2016, doi: 10.18601/17941113.n9.04.
- [279] L. Jiménez Moscovitz and P. Renginfo Rengifo, "Al interior de una máquina de soporte vectorial," *Rev. Ciencias*, vol. 14, pp. 73–85, 2010, doi: 10.25100/rc.v14i0.655.
- [280] C. MacLeod, "Fourier Transforms With scipy.fft: Python Signal Processing," *Real Python*, Dec. 02, 2020. <https://realpython.com/python-scipy-fft/> (accessed Apr. 15, 2021).
- [281] Scipy, "Fourier Transforms (scipy.fft)," *Scipy.org*, Mar. 25, 2021. <https://docs.scipy.org/doc/scipy/reference/tutorial/fft.html> (accessed Apr. 15, 2021).
- [282] N. Urquiza, "Aplicación de las series de Fourier a un circuito excitado por una señal periódica," Bahía Blanca, Argentina, Dec. 2011. Accessed: Apr. 15, 2021. [Online]. Available: <http://lcr.uns.edu.ar/fvc/NotasDeAplicacion/FVC-NicolásUrquiza.pdf>.
- [283] F. G. Supervielle Brouqués, "Digitalización del Sonido," Bahía Blanca, Argentina, Sep. 2011. Accessed: Apr. 15, 2021. [Online]. Available: <http://lcr.uns.edu.ar/fvc/NotasDeAplicacion/FVC-GastonSupervielle.pdf>.
- [284] D. Revelo Luna, *Transformada Discreta de Fourier - Análisis de Señales en Tiempo Real*. 2020.
- [285] B. Medina, J. E. Sierra, and A. B. Ulloa, "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, [Online]. Available:

<https://www.revistaespacios.com/a18v39n22/18392236.html>.

- [286] D. A. Zea Paredes and J. M. Arévalo Villacrés, “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.
- [287] C. I. Araujo, “Transformada discreta de Fourier: propiedades, aplicaciones, ejemplos,” *lifeder.com*, Jul. 14, 2019. <https://www.lifeder.com/transformada-discreta-de-fourier/> (accessed Apr. 15, 2021).
- [288] F. Rosin, P. Forget, S. Lamouri, and R. Pellerin, “Enhancing the Decision-Making Process through Industry 4.0 Technologies,” *Sustainability*, vol. 14, no. 1, p. 461, Jan. 2022, doi: 10.3390/su14010461.
- [289] M. L. Hoffmann Souza, C. A. da Costa, G. de Oliveira Ramos, and R. da Rosa Righi, “A survey on decision-making based on system reliability in the context of Industry 4.0,” *J. Manuf. Syst.*, vol. 56, pp. 133–156, Jul. 2020, doi: 10.1016/j.jmsy.2020.05.016.
- [290] J. Yan, Y. Meng, L. Lu, and C. Guo, “Big-data-driven based intelligent prognostics scheme in industry 4.0 environment,” in *2017 Prognostics and System Health Management Conference (PHM-Harbin)*, Jul. 2017, pp. 1–5, doi: 10.1109/PHM.2017.8079310.
- [291] N. Medic, Z. Anisic, B. Lalic, U. Marjanovic, and M. Brezocnik, “Hybrid fuzzy multi-attribute decision making model for evaluation of advanced digital technologies in manufacturing: Industry 4.0 perspective,” *Adv. Prod. Eng. Manag.*, vol. 14, no. 4, pp. 483–493, Dec. 2019, doi: 10.14743/apem2019.4.343.
- [292] A. Bousdekis, K. Lepenioti, D. Apostolou, and G. Mentzas, “A Review of Data-Driven Decision-Making Methods for Industry 4.0 Maintenance Applications,” *Electronics*, vol. 10, no. 7, p. 828, Mar. 2021, doi: 10.3390/electronics10070828.
- [293] F. Rosin, P. Forget, S. Lamouri, and R. Pellerin, “Impact of Industry 4.0 on decision-making in an operational context,” *Adv. Prod. Eng. Manag.*, vol. 16, no. 4, pp. 500–514, Dec. 2021, doi: 10.14743/apem2021.4.416.
- [294] M. Erdogan, B. Ozkan, A. Karasan, and I. Kaya, “Selecting the Best Strategy for Industry 4.0 Applications with a Case Study,” in *Industrial Engineering in the Industry 4.0 Era*, 2018, pp. 109–119.
- [295] V. Terziyan, S. Gryshko, and M. Golovianko, “Patented intelligence: Cloning human decision models for Industry 4.0,” *J. Manuf. Syst.*, vol. 48, pp. 204–217, Jul. 2018, doi: 10.1016/j.jmsy.2018.04.019.
- [296] A. Mardani, A. Jusoh, K. MD Nor, Z. Khalifah, N. Zakwan, and A. Valipour, “Multiple criteria decision-making techniques and their applications – a review of the literature from 2000 to 2014,” *Econ. Res. Istraživanja*, vol. 28, no. 1, pp.

516–571, Jan. 2015, doi: 10.1080/1331677X.2015.1075139.

- [297] J. Mayor, S. Botero, and J. D. González-Ruiz, “Modelo de decisión multicriterio difuso para la selección de contratistas en proyectos de infraestructura: caso Colombia,” *Obras y Proy.*, vol. 20, pp. 56–74, 2016, Accessed: Mar. 13, 2022. [Online]. Available: <https://scielo.conicyt.cl/pdf/oyp/n20/art05.pdf>.
- [298] A. Jahan, K. L. Edwards, and M. Bahraminasab, “4 - Multi-criteria decision-making for materials selection,” in *Multi-criteria Decision Analysis for Supporting the Selection of Engineering Materials in Product Design (Second Edition)*, Second Edition., A. Jahan, K. L. Edwards, and M. Bahraminasab, Eds. Butterworth-Heinemann, 2016, pp. 63–80.
- [299] A. Kolios, V. Mytilinou, E. Lozano-Minguez, and K. Salonitis, “A comparative study of multiple-criteria decision-making methods under stochastic inputs,” *Energies*, vol. 9, no. 7, Jul. 2016, doi: 10.3390/en9070566.
- [300] H. Karunathilake, E. Bakhtavar, G. Chhipi-Shrestha, H. R. Mian, K. Hewage, and R. Sadiq, “Chapter Seven - Decision making for risk management: A multi-criteria perspective,” in *Methods in Chemical Process Safety*, vol. 4, F. I. Khan and P. R. Amyotte, Eds. Elsevier, 2020, pp. 239–287.
- [301] B. Ceballos, M. T. Lamata, D. Pelta, and J. M. Sanchez, “EL MÉTODO TOPSIS RELATIVO VS. ABSOLUTO,” *Rev. Electrónica Comun. y Trab. ASEPUMA*, vol. 14, pp. 181–192, 2013.
- [302] E. Triantaphyllou, “Multi-Criteria Decision Making Methods,” in *Multi-criteria Decision Making Methods: A Comparative Study*, E. Triantaphyllou, Ed. Boston, MA: Springer US, 2000, pp. 5–21.
- [303] W. Sałabun and A. Piegat, “Comparative analysis of MCDM methods for the assessment of mortality in patients with acute coronary syndrome,” *Artif. Intell. Rev.*, vol. 48, no. 4, pp. 557–571, Dec. 2017, doi: 10.1007/s10462-016-9511-9.
- [304] J. Damidavičius, M. Burinskiene, and J. Antuchevičiene, “Assessing sustainable mobility measures applying multicriteria decision making methods,” *Sustain.*, vol. 12, no. 15, 2020, doi: 10.3390/su12156067.
- [305] I. Siksnylyte, E. Zavadskas, D. Streimikiene, and D. Sharma, “An Overview of Multi-Criteria Decision-Making Methods in Dealing with Sustainable Energy Development Issues,” *Energies*, vol. 11, no. 10, p. 2754, Oct. 2018, doi: 10.3390/en11102754.
- [306] E. A. Adalı and A. Tuş, “Hospital site selection with distance-based multi-criteria decision-making methods,” *Int. J. Healthc. Manag.*, vol. 14, no. 2, pp. 534–544, Apr. 2021, doi: 10.1080/20479700.2019.1674005.
- [307] X. Zhongyou, “Study on the Application of TOPSIS Method to the Introduction of Foreign Players in CBA Games,” *Phys. Procedia*, vol. 33, pp. 2034–2039,

2012, doi: <https://doi.org/10.1016/j.phpro.2012.05.320>.

- [308] V. Yadav, S. Karmakar, P. P. Kalbar, and A. K. Dikshit, "PyTOPS: A Python based tool for TOPSIS," *SoftwareX*, vol. 9, 2019, doi: 10.1016/j.softx.2019.02.004.
- [309] L. Pérez-Domínguez, J. Luis Macías-García, K. Yohana Sánchez-Mojica, and D. Luviano-Cruz, "Comparación Método multi-criterio TOPSIS y MOORA para la optimización de un proceso de inyección de plástico," *Mundo Fesc*, no. 14, pp. 98–105, 2017, [Online]. Available: <https://orcid.org/0000-0003->.
- [310] "EMOTIV EPOC+ 14 Channel Mobile Brainwear®," *Emotiv*. <https://www.emotiv.com/product/emotiv-epoc-14-channel-mobile-eeg/#> (accessed Oct. 16, 2022).
- [311] D. F. D’Croz Barón, "Reconocimiento de Imaginación Motora de Señales EEG en el Dominio Temporal aplicando Modelos Paramétricos," Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE), Tenantzintla, Puebla, 2011.
- [312] F. Laencina Escobar, "Predicción del pensamiento motor mediante señales de electroencefalograma EEG," Universidad Politécnica de Cartagena, Cartagena, 2019.
- [313] Cymaticcorps, "Cykit." Cymaticcorp, 2017, [Online]. Available: <https://github.com/CymatiCorp/CyKit>.
- [314] OpenVibe, "OpenVibe Software for Brain Computer Interfaces and Real Time Neurosciences," *OpenVibe*, Jul. 2022. <http://openvibe.inria.fr/> (accessed Oct. 17, 2022).
- [315] O. Roesler, "EEG Eye State Data Set." UCI Machine Learning Repository, Stuttgart, Germany, 2013, [Online]. Available: <https://archive.ics.uci.edu/ml/datasets/EEG+Eye+State>.
- [316] C. A. Martínez Díaz, "Aprendizaje Automático en la Interpretación de Señales Electroencefalográficas," Universidad Autónoma de Aguascalientes, Aguascalientes, 2022.
- [317] S. Gu, R. Cheng, and Y. Jin, "Feature selection for high-dimensional classification using a competitive swarm optimizer," *Soft Comput.*, vol. 22, no. 3 LB-Gu2018, pp. 811–822, 2018, doi: 10.1007/s00500-016-2385-6.
- [318] C. Wang, Q. Hu, X. Wang, D. Chen, Y. Qian, and Z. Dong, "Feature Selection Based on Neighborhood Discrimination Index," *IEEE Trans. Neural Networks Learn. Syst.*, vol. 29, no. 7, pp. 2986–2999, 2018, doi: 10.1109/TNNLS.2017.2710422.
- [319] R. Spasova Dimitrova, "Desarrollo y evaluación de métodos de selección de características para la predicción de eventos adversos en pacientes polimedicados," Universidad Pública de Navarra, España, 2017.

- [320] A. E. Gallegos Acosta, M. D. TORRES SOTO, F. J. ALVAREZ RODRIGUEZ, and A. TORRES SOTO, "INTEGRACIÓN DEL OPERADOR DE ALTERACIÓN A METAHEURÍSTICAS EVOLUTIVAS PARA LA APLICACIÓN DE LA TEORÍA DE TESTORES EN PATOLOGÍAS MÉDICAS," *DYNA NEW Technol.*, vol. 6, no. 1, p. [12 p.]-[12 p.], 2019, doi: 10.6036/NT9093.
- [321] A. E. GALLEGOS ACOSTA, M. D. TORRES SOTO, F. J. ALVAREZ RODRIGUEZ, and A. TORRES SOTO, "MANIPULATION OF METAHEURISTICS FOR THE SEARCH OF TYPICAL TESTERS," *DYNA*, vol. 95, no. 1, pp. 11–11, Jan. 2020, doi: 10.6036/9375.
- [322] W. Pereira, "Desafíos de la Inteligencia Artificial Bioinspirada con Algoritmos Genéticos," 2018, vol. 20, no. 2, p. 27, [Online]. Available: <http://revistasenlinea.saber.ucab.edu.ve/temas/index.php/tekhne/article/view/3577/3066>.
- [323] S. N. Sivanandam and S. N. Deepa, *Introduction to genetic algorithms*. Berlín: Springer Science & Business Media.
- [324] R. Pérez-Rodríguez and A. Hernández-Aguirre, "Un algoritmo de estimación de distribuciones copulado con la distribución generalizada de Mallows para el problema de ruteo de autobuses escolares con selección de paradas," *Rev. Iberoam. automática e informática Ind.*, vol. 14, pp. 288–298, doi: <https://doi.org/10.1016/j.riai.2017.05.002>.
- [325] W. H. Wolberg, N. Street, and O. L. Mangasarian, "Wisconsin Diagnostic Breast Cancer (WDBC)." USA, 1995, [Online]. Available: <https://archive.ics.uci.edu/ml/datasets/Breast+Cancer+Wisconsin+%28Diagnostic%29>.
- [326] J. D. Villegas Alzate, L. M. Martínez Sánchez, and L. I. Jaramillo Jaramillo, "Calidad de vida: un aspecto olvidado en el paciente con hemofilia," *Arch. Med.*, vol. 18, p. 11, 2018, doi: <https://doi.org/10.30554/archmed.18.1.2584.2018>.
- [327] S. Berres, A. Coronel, and R. Lagos, "Solución numérica de un problema inverso aplicado a un algoritmo genético continuo," *Rev. Integr. temas matemáticas*, vol. 36, pp. 67–81, doi: <http://dx.doi.org/10.18273/revint.v36n2-2018001>.
- [328] Y. Martínez-López, J. Madera Quintana, and I. Leguen de Varona, "Algoritmos Evolutivos con Estimación de Distribución Celulares," *Rev. Cuba. Ciencias Informáticas*, vol. 10, pp. 159–170, 2016, [Online]. Available: http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S2227-18992016000500012&nrm=iso.
- [329] E. Bengoetxea, P. Larrañaga, I. Bloch, and A. Perchant, "Estimation of Distribution Algorithms: A New Evolutionary Computation Approach for Graph Matching Problems," 2001, pp. 454–469.

- [330] M. D. Torres Soto and E. E. Ponce de León Sentí, "Metaheurísticas híbridas en selección de subconjuntos de características para aprendizaje no supervisado," Universidad Autónoma de Aguascalientes, Aguascalientes, 2010.
- [331] Exponentis, "Discretización de un Pandas dataframe en Python manteniendo el nombre de las columnas," *Aprendizaje Estadístico y Minería de Datos*, Sep. 30, 2019. <http://exponentis.es/discretizacion-de-datos-en-python-manteniendo-el-nombre-de-las-columnas#:~:text=La discretización de variables es,funcionar mejor de forma continua.> (accessed Oct. 21, 2022).
- [332] D. Barajas, D. Torres, and A. Torres, "DBT an Algorithm Based on CUDA for Reducing the Time to Obtain Typical Testors," *Res. Comput. Sci.*, vol. 150, no. 9, 2021.
- [333] A. E. Gallegos Acosta, M. D. Torres Soto, A. Torres Soto, and E. E. Ponce de León Sentí, "Contrastación de algoritmos de aprendizaje automático para la clasificación de señales EEG Machine Learning Algorithms Testing for EEG Signal Classification," *Res. Comput. Sci.*, vol. 149, no. 8, pp. 515–525, 2020, Accessed: Jun. 08, 2021. [Online]. Available: https://www.rcs.cic.ipn.mx/2020_149_8/Contrastacion de algoritmos de aprendizaje automatico para la clasificacion de senales EEG.pdf.
- [334] J. Carlos Cubero and F. Berzal, "Introducción a SPSS," *Sistemas Inteligentes de Gestión*. <https://elvex.ugr.es/decsai/intelligent/workbook/D0 SPSS.pdf> (accessed May 25, 2020).
- [335] J. Martínez Heras, "Máquinas de Vectores de Soporte (SVM)," *IArtificial.net*. https://iartificial.net/maquinas-de-vectores-de-soporte-svm/#El_truco_del_kernel_en_SVM (accessed Jun. 03, 2020).
- [336] Scikit-learn developers, "Sklearn.svm.SVC," *Scikit learn*, 2019. <https://scikit-learn.org/stable/modules/generated/sklearn.svm.SVC.html> (accessed Jun. 03, 2020).
- [337] J.-P. Lévy Magin, R. Flórez López, and J. M. Fernández Fernández, *Las Redes Neuronales Artificiales. Fundamentos teóricos y aplicaciones prácticas*, 1st ed. España, 2008.
- [338] D. I. Paz Villaseca, "Herramientas Deep Learning para Predictive Analytics.," Universidad de Concepción, 2017.
- [339] S. Torres López, M. Lazara, A. Cuza, P. Y. Piñero Perez, and L. A. Piedra Diéguez, "Red neuronal multicapa para la evaluación de competencias laborales Multilayer neural network for assessment of labor competences," *Rev. Cuba. Ciencias Informáticas*, vol. 10, 2016.
- [340] R. Lippmann, "An introduction to computing with neural nets," *IEEE ASSP Mag. ASSP Mag. IEEE, IEEE ASSP Mag.*, vol. 4, no. 2, pp. 4-4–22, 1987, doi:

10.1109/MASSP.1987.1165576.

- [341] I. Corso and C. Lorena, “Aplicación de algoritmos de clasificación supervisada usando Weka,” Córdoba, 2009. [Online]. Available: http://www.investigacion.frc.utn.edu.ar/labsis/Publicaciones/congresos_labsis/cynthia/CNIT_2009_Aplicacion_Algoritmos_Weka.pdf.
- [342] J. I. Barrios Arce, “La matriz de confusión y sus métricas,” *Health Big Data*, Jul. 26, 2019. <https://www.juanbarrios.com/la-matriz-de-confusion-y-sus-metricas/> (accessed Apr. 16, 2021).
- [343] A. D. Pano Azucena, “Realización FPGA de una Red Neuronal Artificial para Reproducir Comportamiento Caótico,” Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE), Puebla, 2015.
- [344] Xpikuos, *PERCEPTRON REDES NEURONALES: CAPAS OCULTAS, HIPERPARAMETROS, NEURONAS POR CAPA (2021) | IA*. España: Youtube, 2018.
- [345] Á. Franco García, “Histéresis de la partícula,” *Dinámica de la partícula*. <http://www.sc.ehu.es/sbweb/ocw-fisica/dinamica/estabilidad/estabilidad2/histeresis.shtml> (accessed Nov. 21, 2022).
- [346] J. C. Trejo García, E. C. Rivera Hernández, and H. Ríos Bolívar, “Análisis de la histéresis del desempleo en México ante shocks macroeconómicos,” *Contaduría y Adm.*, vol. 62, no. 4, pp. 1228–1248, Oct. 2017, doi: 10.1016/j.cya.2017.06.005.
- [347] IMA, “¿Qué es la histéresis?,” *imamagnets.com*, 2018. <https://imamagnets.com/blog/que-es-la-histeresis/> (accessed Nov. 21, 2022).
- [348] A. C. Guyton and J. E. Hall, *Tratado de Fisiología médica*, 9th ed. Philadelphia, Pennsylvania: McGraw Hill Interamericana, 1996.

Anexos

A. Publicaciones

A.1 Integración del operador de alteración a metaheurísticas evolutivas para la aplicación de la teoría de testores en patologías médicas

E. Gallegos Acosta, M. D. Torres Soto, F. J. Álvarez Rodríguez, and A. Torres Soto, "Integración del operador de alteración a metaheurísticas evolutivas para la aplicación de la teoría de testores en patologías médicas," DYNA NEW Technol., vol. 6, no. 1, p. [12 p.]- [12 p.], 2019. DOI: <https://doi.org/10.6036/NT9093>

INDICES: Google Scholar, CrossRef, MIAR, DULCINEA, Catálogo 2.0 Latindex, Microsoft Academic, Indices CSIC, Cabells' Journal Whitelist, DIMENSIONS, LENS 1FINDR, Dialnet, Scilit.net

Resumen

El presente artículo presenta el diseño e integración del "operador de alteración" a metaheurísticas evolutivas (AG y EDA), con el objetivo es la búsqueda de testores típicos para la selección de características a datos médicos. Este operador funciona como soporte en la exploración del espacio de soluciones evitando la búsqueda aleatoria. Las metaheurísticas híbridadas encuentran los testores típicos asociados a los datos analizados que son subconjuntos irreducibles capaces de realizar clasificación. Para interpretar los testores típicos encontrados se calculó el peso informacional para determinar el impacto de cada característica en el proceso de clasificación. Finalmente, se presenta la afinación y contrastación de

metaheurísticas para encontrar los mejores valores de parámetros que mejoran su desempeño y determinar la metaheurística más adecuada para cada patología.

Palabras clave

Operador de alteración, algoritmo genético, algoritmo de estimación de la distribución, teoría de testores, selección de subconjuntos de características.

1

The screenshot shows the website interface for 'DYN New Technologies'. The main article is titled 'INTEGRACIÓN DEL OPERADOR DE ALTERACIÓN A METAHEURÍSTICAS EVOLUTIVAS PARA LA APLICACIÓN DE LA TEORÍA DE TESTORES EN PATOLOGÍAS MÉDICAS'. The article is from January-December 2019, Volume 6, Pages 12. The authors listed are Alexis Edmundo Galleos Acosta, María Dolores Torres Soto, and Francisco Javier Álvarez Rodríguez. The subject is 'CIENCIA DE LOS ORDENADORES (INTELIGENCIA ARTIFICIAL)'. There are options to download the PDF and a payment section for PayPal or credit cards. The page also features a search bar, navigation menu, and social media links.

1 Artículo disponible en: <https://www.dyna-newtech.com/Articulos/Ficha.aspx?idMenu=ae91868c-6abc-4b57-803c-4a45e646d0b8&Cod=9093&codigoacceso=6dc1fa58-223c-4f61-9189-cfebb2164240>

A.2 Clasificación de señales electroencefalográficas por medio de un clasificador bayesiano

E. Gallegos Acosta, M. D. Torres Soto, F. J. Álvarez Rodríguez, and A. Torres Soto, "Clasificación de señales electroencefalográficas por medio de un clasificador bayesiano". Memorias del Congreso Investigación en el Posgrado, 2019.

CLASIFICACIÓN DE SEÑALES ELECTROENCEFALOGRÁFICAS POR MEDIO DEL CLASIFICADOR BAYESIANO, ALEXIS EDMUNDO GALLEGOS ACOSTA.

INTRODUCCIÓN: El estudio del cerebro ha tenido un particular interés por parte de la ciencia. En consecuencia, se han creado nuevas herramientas y métodos para encontrar solución a patologías y trastornos asociados al cerebro. Ejemplo de ello, es la creación del electroencefalograma (EEG), un dispositivo que permite la captura de la actividad bioeléctrica del cerebro por medio de electrodos situados en el cuero cabelludo o corteza cerebral. Este dispositivo tiene la capacidad de generar una gran cantidad de datos cuya clasificación puede ser imprecisa debido a interferencias, tejidos intermedio y alta variabilidad en las señales del cerebro. Es por ello, que el análisis de las señales electroencefalográficas es un área de oportunidad para el aprendizaje automático y la minería de datos. Así pues, en el presente reporte se expone la clasificación de señales electroencefalográficas por medio del clasificador ingenuo de Bayes, aprovechando la simplicidad de su construcción, así como la robustez como clasificador.

OBJETIVO: Diseñar, implementar y probar un clasificador ingenuo de Bayes para la clasificación de señales electroencefalográficas.

METODOLOGÍA: Las señales a clasificar fueron obtenidas del repositorio de aprendizaje máquina de la UCI. Este conjunto de datos contiene 14,980 registros divididos en dos clases: clase 0 (ojo abierto)

y la clase 1 (ojo cerrado). Las instancias son descritas por 14 características correspondientes a los electrodos del dispositivo EEG EPOC+ de Emotiv. Dichos registros fueron preprocesados por medio de la normalización Z. Finalmente, se utilizó alrededor del 80% de los registros para crear el modelo probabilístico del clasificador bayesiano y el resto para la validación de este.

RESULTADOS: Al evaluar el modelo creado por la implementación del clasificador ingenuo de Bayes, se observó que dicho modelo logró una exactitud del 94.31% al clasificar correctamente 2785 instancias de las 2953 instancias para la validación del modelo.

CONCLUSIÓN: El clasificador ingenuo de Bayes es de los clasificadores más simples y uno de los más utilizados. Como se observa en el apartado de resultados, el clasificador tiene mucho potencial y robustez en la clasificación supervisada. Por otro lado, mejorar la clasificación de señales de EEG es una tarea importante del aprendizaje automático ya que representa un recurso novedoso para el procesamiento de la actividad neuronal para su reconocimiento y la determinación de relaciones que permitan avances en el diagnóstico de patologías, así como la creación de nuevos paradigmas en el control de videojuegos, prótesis, herramientas de comunicación, etc.

BIBLIOGRAFÍA: Espinosa, L. (2016). Electroencefalografía Inalámbrica: Una mirada actual y propuesta de sistema portátil. Roesler, O. (2013). EEG Eye State Data Set. Retrieved from UCI Machine Learning Repository

Universidad Autónoma de Aguascalientes
Doctorado en Ciencias Aplicadas y Tecnologías
alexisedmi@gmail.com

Tutor: Doctora MARÍA DOLORES TORRES SOTO

A.3 Manipulación de metaheurísticas para la búsqueda de testores típicos

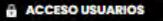
E. Gallegos Acosta, M. D. Torres Soto, F. J. Álvarez Rodríguez, and A. Torres Soto, "Manipulación De Metaheurísticas Para La Búsqueda De Testores Típicos" DYNA, Jan2020, Vol. 95, Issue 1, p11-11, 1p. DOI: <http://dx.doi.org/10.6036/9375>

INDICES: Science Citation Index, Journal Citation Reports (JCR, Clarivate Analytics), Scopus (Elsevier), Pascal (CNRS), Recyt, Ulrich's International Periodicals Directory (Elsevier), Technology Research Database, Catálogo 2.0 Latindex (36/36), Georef, Dialnet, ICYT, CIRC, Inspec, Google Scholar, Microsoft Academic, DIMENSIONS, LENS, 1FINDR, Scilit.net.

Resumen

Una de las tareas del reconocimiento de patrones es la selección de subconjuntos de características (SSC), que permite identificar características que aporten información relevante. Existen diferentes enfoques para aplicar SSC siendo el enfoque lógico-combinatorio por medio de la teoría de testores, una herramienta muy utilizada. Un testor es un subconjunto de características capaz de distinguir objetos de distintas clases. Los testores en su mínima expresión son conocidos como testores típicos (TT). Encontrarlos permite distinguir variables relevantes de las redundantes o irrelevantes, de manera que los modelos de análisis de datos se vuelven más sencillos y comprensibles, mejorando su desempeño y disminuyendo requerimientos computacionales.

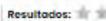
2

ENVÍO ARTÍCULOS SUSCRIPCIÓN  ENGLISH ESPAÑOL 

DYNA Ingeniería e Industria 

Publicaciones DYNA Revista Autores y Evaluadores Artículos Noticias Blogs y Comunidad Suscribirse Anunciar Contactar Buscar Alta en Web

Búsqueda Homepage Artículos Búsqueda

Voto:  Resultados:  0 Votos  

MANIPULACIÓN DE METAHEURÍSTICAS PARA LA BÚSQUDA DE TESTORES TÍPICOS

ENERO 2020 - Volumen: 95 - Páginas: 11
 DOI: <https://doi.org/10.6036/9375>
 AUTORES: ALEXIS EDUARDO GALLEGOS ACOSTA - MARÍA DOLORES TORRES SOTO - FRANCISCO JAVIER ALVAREZ RODRIGUEZ - AURORA TORRES SOTO
 MATERIAS: CIENCIA DE LOS ORDENADORES (INTELIGENCIA ARTIFICIAL)
 DESCARGAS: 11
 COMO REFERENCIAR ESTE ARTÍCULO: [Ver referencia](#) 

¿Le interesa este artículo? Puede comprar el artículo a través de la plataforma de pago de PayPal o tarjeta de crédito (VISA, MasterCard,...) por 20 €.



METADATOS EN BREVE ARTÍCULOS RELACIONADOS

Palabras clave: Operador de alteración, algoritmo genético, algoritmo de estimación de la distribución, teoría de testores, selección de subconjuntos de características

Tipo de artículo: NOTA TÉCNICA / TECHNICAL NOTE

Sección: NOTAS TÉCNICAS / TECHNICAL NOTES

Una de las tareas del reconocimiento de patrones es la selección de subconjuntos de características (SSC), que permite identificar características que aporten información relevante; existen diferentes enfoques para aplicar SSC siendo el enfoque lógico-combinatorio por medio de la teoría de testores, una herramienta muy utilizada. Un testor es un subconjunto de características capaz de distinguir objetos de distintas clases. Los testores en su mínima expresión son conocidos como testores típicos (TT). Encontrarlos permite distinguir variables relevantes de las redundantes o irrelevantes, de manera que los modelos de análisis de datos se vuelven más sencillos y comprensibles, mejorando su desempeño y disminuyendo requerimientos computacionales.

Compartémoslo:  Más redes sociales

 **BUSCAR CONTENIDOS**
SEARCH CONTENTS

PUBLICACIONES DYNA S. CONVOCATORIA:
CONSEJO ADMINISTRACIÓN Y JUNTA GENERAL

- LUGAR: Online
- HORA: 11:30 (CA) 17:00 (ES)
- DÍA: MARTES, 24 de diciembre de 2021





 Secured by PayPal 

Tweets by @revistadyna

 **RevistaDYNA** @revistadyna

ARTICLE PUBLISHED IN DYNA: EXPERIMENTAL COMPARATIVE STUDY BETWEEN JMPPT, HYBRID P&O AND #FUZZY CONTROL FOR A SMALL WIND TURBINE APPLICATION doi.org/10.6036/ES10295

Nov 25, 2021

 **RevistaDYNA** @revistadyna

ABASTECIMIENTO DE #HIDROGENO LIQUIDO PARA #BUQUES DE CERO EMISIONES. La instalación es vital para alimentar un sector marítimo internacional que representa alrededor de mil millones de toneladas de emisiones. revistadyna.com/noticias-de-in-



Embed [View on Twitter](#)

© Revista de Ingeniería Dyna 2006 - Publicaciones DYNA
 Órgano Oficial de Ciencia y Tecnología de la Federación de Asociaciones de Ingenieros Industriales
 Dirección: Alameda Mazorra 69 - 2º - 48009-Bilbao SPAIN
 Teléfono: +34 944 227956. Fax: +34 944 234461. Email: dyna@revistadyna.com

2 Artículo disponible en: <https://www.revistadyna.com/busqueda/manipulacion-de-metaheuristicas-para-busqueda-de-testores-tipicos>

A.4 Contrastación de algoritmos de aprendizaje automático para la clasificación de señales EEG

E. Gallegos Acosta, M. D. Torres Soto, A. Torres Soto, and E. E. Ponce de León Sentí, "Contrastación de algoritmos de aprendizaje automático para la clasificación de señales EEG³". Research in Computer Science, vol. 149, no. 8, pp. 515-525, 2020.

INDICES: DBLP, LatIndex, Periódica

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 intensidad 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.

³ Artículo disponible en:

https://www.rcs.cic.ipn.mx/2020_149_8/Contrastacion%20de%20algoritmos%20de%20aprendizaje%20automatico%20para%20la%20clasificacion%20de%20senales%20EEG.pdf

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 Senti

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.

Alexis Edmundo Gallegos Acosta, María Dolores Torres Soto, Aurora Torres Soto, et al.

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 imaginación 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].

Alexis Edmundo Gallegos Acosta, María Dolores Torres Soto, Aurora Torres Soto, et al.

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].

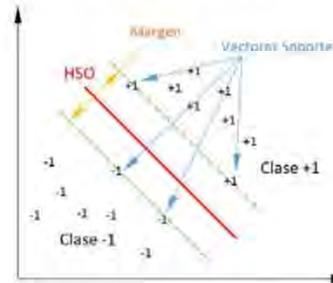


Fig. 1. Funcionamiento de una SVM [24].

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.

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

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.

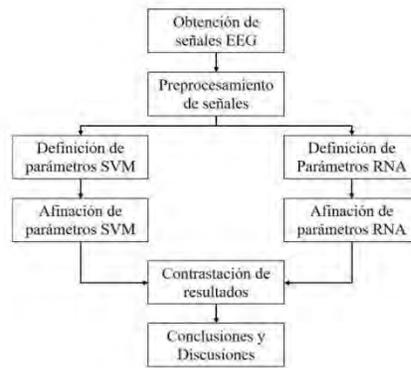


Fig. 2. Metodología.

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 se 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.

Alexis Edmundo Gallegos Acosta, María Dolores Torres Soto, Aurora Torres Soto, et al.

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%.

Alexis Edmundo Gallegos Acosta, María Dolores Torres Soto, Aurora Torres Soto, et al.

Tabla 3. Mejores modelos en SVM y RNA.

Modelo	Configuración	E.	P (+)	P (-)	R. F (+)	R. F (-)
RNA 1 capa	C1:75, A: relu, Epoc: 100, Batch: 5	95.71	95.60	95.88	4.11	4.39
RNA 2 capas	C1: 75, A: relu, C2: 15, A: relu, Epoc: 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)

Alexis Edmundo Gallegos Acosta, María Dolores Torres Soto, Aurora Torres Soto, et al.

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/?c=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.aramex.com.mx/blog/8-algoritmos-aprendizaje-automatico-data-mining-mas-usados-aramex-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. Cymaticcorps: 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*

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

- automático aplicadas a electroencefalogramas. *Research in Computer Science*, 113. Instituto Politécnico Nacional, pp. 53–65 (2016)
31. Salamanca-Polo, I.: 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.cienciadedatos.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)

A.5 Tratamiento de señales electroencefalográficas de imaginación motora con fines de clasificación

A. E. Gallegos Acosta, M. D. Torres Soto, A. Torres Soto, and E. E. Ponce de León Sentí, "Tratamiento de Señales Electroencefalográficas de Imaginación Motora con Fines de Clasificación", Research in Computer Science, COMIA 2021. (En proceso de publicación).

INDICES: DBLP, LatIndex, Periódica

NOTA: En proceso de publicación

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.

14/9/22, 11:38

Gmail - COMIA 2021 notificación del artículo 126



Alexis Gallegos <alexisedm@gmail.com>

COMIA 2021 notificación del artículo 126

3 mensajes

COMIA 2021 <comia2021@easychair.org>
Para: Alexis Gallegos <alexisedm@gmail.com>

12 de mayo de 2021, 0:03

Estimada(o) Alexis Gallegos,

Nos complace informarle que su artículo:
Tratamiento de Señales Electroencefalográficas de Imaginación Motora con Fines de Clasificación
ha sido ACEPTADO.

Su artículo será publicado como número especial de la revista "Research in Computing Science", de publicación periódica con ISSN, indexada en LatIndex y DBLP.

Los artículos no deberán exceder de 14 páginas y el artículo final deberá ser presentado en el formato de las plantillas para Word o Latex disponibles en la página web www.smia.mx/comia/2021.

El conjunto de revisiones de su artículo está al final de este mensaje. Por favor, tome en cuenta las recomendaciones recibidas para preparar la versión final, misma que deberá ser enviada para el 19 de mayo de 2021.

En breve les compartiremos la página para hacemos llegar su versión final, las credenciales de acceso, y otra información complementaria.

Posteriormente recibirá información sobre su presentación en el COMIA 2021.

Atentamente,

Presidentes del Comité de Programa del COMIA 2021

SUBMISSION: 126
TITLE: Tratamiento de Señales Electroencefalográficas de Imaginación Motora con Fines de Clasificación

----- REVIEW 1 -----

SUBMISSION: 126
TITLE: Tratamiento de Señales Electroencefalográficas de Imaginación Motora con Fines de Clasificación
AUTHORS: Alexis Gallegos, María Dolores Torres Soto, Aurora Torres Soto and Eunice Esther Ponce de León Sentí

----- Overall evaluation -----

SCORE: 0 (borderline paper)

----- TEXT:

En este manuscrito se presentan los efectos de la normalización sobre la clasificación de series de tiempo provenientes de muestras electroencefalográficas de imaginación motora utilizando 2 tratamientos de datos: normalización y su descomposición en sus componentes de frecuencia usando la FFT. Este tratamiento es usado para clasificar entre dos señales de imaginación motora correspondientes a "abrir mano" y "cerrar mano". El trabajo es una aplicación interesante sobre el pre-procesamiento requerido para la clasificación de series de tiempo aplicado al estudio de señales electroencefalográficas, sin embargo existen los siguientes comentarios mayores:

*
Es un hecho bien conocido que para la clasificación y comparación de similitud de secuencias de series de tiempo, es un requisito la normalización de las series de tiempo (via z-score) para compararlas con las mismas amplitudes (10.1145/882082.882086). En este sentido, las comparaciones contra los datos crudos son irrelevantes y la anterior referencia debe ser incluida.

*
El resumen del trabajo necesita ser reescrito. El objetivo del resumen es presentar el problema a grandes rasgos, la propuesta del trabajo, los resultados y como estos contribuyen al desarrollo del conocimiento en la clasificación de series de tiempo. En su estado actual, no cumple con estas características.

<https://mail.google.com/mail/u/0/?ik=99ed18cdd9&view=pt&search=all&permthid=thread-f%3A1699527588634158110&simpl=msg-f%3A1699527588...> 1/3

14/9/22, 11:38

Gmail - COMIA 2021 notificación del artículo 126

Las secciones del artículo deben ser Introducción, Materiales y Métodos, Experimentos, Conclusión/Discusiones. En su estado actual, el manuscrito no cumple con estas características.

La introducción debe mejorarse. El objetivo de esta sección es ampliar el resumen, con la misma secuencia que el resumen: problema detallado, las formas en las que se ha abordado este problema (estado del arte), la propuesta de los autores y la descripción del contenido del artículo. El estado del arte debe ser integrado en la introducción (imaginación motora); las señales encefalográficas sin la parte referente al hardware emotiv.

En la sección de materiales y métodos primero se deberá describir la metodología (fig.2) así como la descripción que la acompaña. Posteriormente se deben describir los materiales (base de datos de EEG, el hardware con el que se generaron los datos como la fig.3, y otros detalles relevantes como número de clases, proporciones, número de dimensiones, etc) y los métodos: normalización de la serie de tiempo; FFT removiendo la figura 1 ya que es una técnica ampliamente conocida y basta con utilizar una referencia; la sección 2.4 debería describir las máquinas de vectores de soporte (en su lugar se describe lo que es aprendizaje automático), parámetros de las SVM. En esta sección también debe describirse la configuración del experimento, las veces que se repitió, las proporciones de datos usadas (80% entrenamiento/20% validación). Estos conjuntos de datos son disjuntos? Falta clarificar.

En el sentido del comentario anterior, la presentación de los resultados puede mejorarse usando una de las siguientes dos formas: 1) el uso de una tabla donde se muestren las medias y desviaciones estandar para los algoritmos respecto a Recall, precision, specificity y f1, o 2) con una figura que muestre la misma relación que la tabla, pero usando diagramas de violín (<https://seaborn.pydata.org/generated/seaborn.violinplot.html>, ej. figura 3). Esto permitirá sintetizar los resultados y compararlos de manera directa sin tener que estar cambiando de página.

Otros cambios menores son:

- * La figura 2 debe ser revisada, el último punto debería ser el análisis de resultados, no conclusiones.
- * En la sección de conclusiones y trabajo futuro, no se dice nada del trabajo futuro.

Por lo anterior recomiendo cambios mayores.

----- REVIEW 2 -----

SUBMISSION: 126

TITLE: Tratamiento de Señales Electroencefalográficas de Imaginación Motora con Fines de Clasificación

AUTHORS: Alexis Gallegos, María Dolores Torres Soto, Aurora Torres Soto and Eunice Esther Ponce de León Sentí

----- Overall evaluation -----

SCORE: 1 (weak accept)

---- TEXT:

El artículo presenta resultados de experimentos para el tratamiento de señales fisiológicas EEG, no hay una contribución evidente al estado del arte, el trabajo está bien estructurado y con una secuencia de ideas adecuada, para que el artículo sea publicado se recomiendan las siguientes correcciones:

1. Para darle un formato adecuado al documento se recomienda referenciar las ecuaciones, asignando un número al costado derecho (1), (2), ... haciendo referencia al número correspondiente, utilizar algún editor de formulas matemáticas para mejorar la calidad de las mismas.
2. El la sección 3 Metodología, no se menciona el tamaño de la muestra de usuarios de los que se recolectó datos crudos EEG, se infiere que fue solo uno, lo cual es una muestra no significativa y en su caso se analiza la señal de un solo sujeto de prueba. Esto se puede subsanar con el uso de dataset de señales EEG que pueden obtenerse en repositorios abiertos.
3. En la sección 4 Resultados, se recomienda modificar las gráficas y la redacción de los párrafos en donde se analizan los resultados evitando hacer referencia a los colores, se recomienda utilizar algún patrón en las gráficas para diferenciar ya que en ocasiones no se cuenta con versiones a color de los artículos lo cual dificulta distinguir los elementos en la gráfica.
4. Hay errores ortográficos menores que es necesario corregir, por ejemplo, se omiten los acentos en éste cuando tiene la función de sustantivo.
5. Hay errores de redacción menores que es necesario corregir, se adjunta el documento con algunos ejemplos.

<https://mail.google.com/mail/u/0/?ik=99ed18cdd9&view=pt&search=all&permthid=thread-f%3A1699527588634158110&simpl=msg-f%3A1699527588...> 2/3

14/9/22, 11:38

Gmail - COMIA 2021 notificación del artículo 126

6. Para complementar el trabajo de investigación es recomendable que se exploren otros algoritmos de clasificación que han demostrado en la literatura mejores resultados, en este caso Redes Neuronales y RF. Buscar dataset de entrenamiento disponibles en repositorios abiertos.

Alexis Gallegos <alexisedm@gmail.com>

12 de mayo de 2021, 9:19

Para: "Dra. María Dolores Torres Soto" <mdtorres@correo.uaa.mx>, "M.C. Aurora Torres Soto" <atorres@correo.uaa.mx>

Buen día,

Le hago llegar el resultado de la evaluación del artículo para COMIA
Saludos,

Alexis

[El texto citado está oculto]

Dra. Aurora Torres <atorres@correo.uaa.mx>

13 de mayo de 2021, 10:56

Para: Alexis Gallegos <alexisedm@gmail.com>

Ok. Saludos

[El texto citado está oculto]

A.6 Procesamiento y clasificación de señales electroencefalográficas con imaginación motora

A. E. Gallegos Acosta, M. D. Torres Soto, A. Torres Soto, and E. E. Ponce de León Sentí, "Procesamiento y clasificación de señales electroencefalográficas con imaginación motora". Memorias del Congreso Investigación en el Posgrado, 2021.

PREPROCESAMIENTO Y CLASIFICACIÓN DE SEÑALES ELECTROENCEFALOGRÁFICAS CON IMAGINACIÓN MOTORA, ALEXIS GALLEGOS, AURORA TORRES SOTO.

INTRODUCCIÓN: La imaginación motora es una representación mental del movimiento sin activación muscular. Esta práctica requiere de las mismas zonas cerebrales involucradas en el movimiento físico. La activación produce señales eléctricas que pueden traducirse en comandos para el control de dispositivos por medio de una interfaz cerebro computadora (BCI). El mayor desafío es su clasificación debido a que las señales cerebrales son una mezcla de información, artefactos fisiológicos y técnicos.

OBJETIVO: Obtener y clasificar señales electroencefalográficas con imaginación motora de abrir y cerrar mano derecha aplicando distintos métodos de preprocesamiento.

METODOLOGÍA: Se trabajó con un conjunto de datos con 23,846 registros y 14 características. Se muestrearon aleatoriamente 5,000 registros. La muestra se replicó cuatro veces para realizar distintos preprocesamientos: un conjunto crudo, uno normalizado (Z-score), uno con FFT y, uno combinando ambos métodos. El siguiente paso fue el entrenamiento y validación de un modelo de máquina de soporte vectorial (SVM). Dicho modelo trabajó con los conjuntos de datos y, cuyo entrenamiento y validación se replicó 30 veces con el fin de realizar un análisis de su comportamiento según el conjunto de datos con el que se alimentó.

RESULTADOS: Cada una de las réplicas se evaluó con las métricas de exactitud, precisión, especificidad, sensibilidad y puntuación F1. El conjunto de datos que combinó la FFT y Z-score, permitió un mejor desempeño del clasificador en las cinco métricas (exactitud>90%) así como una buena distinción entre señales de abrir y cerrar mano. Sin embargo, se observó que la aplicación de normalización por sí sola, permite un desempeño muy cercano al propio del conjunto que combina dos preprocesamientos (exactitud>80%). En cambio, el conjunto de datos crudos y el que recibió solo transformación de Fourier presentan un desempeño por debajo del 60% de exactitud. Además de que el modelo SVM presenta problemas para distinguir señales de cerrar mano.

CONCLUSIÓN: La selección de un método de normalización es de alta importancia, pues de ello depende la calidad y el desempeño de un modelo de aprendizaje automático. En este caso, los datos pertenecen a muestras obtenidas en un tiempo finito específico haciendo que la transformada de Fourier fuera una opción perfecta. Además, su combinación con la normalización Z-score resulta imprescindible pues se elimina el sesgo en la clasificación al trasladar cada característica a una escala común.

BIBLIOGRAFÍA: Z. Tayeb et al., "Validating Deep Neural Networks for Online Decoding of Motor Imagery Movements from EEG Signals," doi: 10.3390/s19010210. J. Lin, E. Keogh, S.Lonardi, and B. Chiu, "A symbolic representation of time series, with implications for streaming algorithms," doi:10.1145/882082.882086

Universidad Autónoma de Aguascalientes
 Doctorado en Ciencias Aplicadas y Tecnología
 alexisedm@gmail.com
 Av. Universidad #840, Aguascalientes Ags

Tutor: Doctora MARÍA DOLORES TORRES SOTO

A.7 Feature subset selection in electroencephalographic signals using typical testors

A. E. Gallegos Acosta, M. D. Torres Soto, A. Torres Soto, and E. E. Ponce de León Sentí, "Feature Subset Selection in Electroencephalographic signals using typical testors." Research in Computer Science, MICAI 2021. (En proceso de publicación).

INDICES: DBLP, LatIndex, Periódica

NOTA: En proceso de publicación

Resumen

Motor imagery (MI) is a mental representation of movement without performing it or even tensing any muscles. MI requires a conscious activation of the same brain regions that involved in actual movement. The use of brain signals has been explored for multiple applications on the field of biomedical engineering such as the development of brain computer interfaces (BCI). BCI systems are designed to translates users' intentions into control signals, commands, or codes. Nevertheless, the major challenge in BCI system development is the classification of MI signal recorded by an electroencephalogram (EEG). This paper focuses on the application of the testor theory and the logical combinatorial pattern recognition approach for feature selection with the aim of reducing the feature representation space for classification tasks. The MI-EEG signals were recorded by the EMOTIV EPOC+ EEG device with 14 electrodes.

Palabras clave

Typical testors, feature subset selection, electroencephalographic signals, motor imagery.



Article ID: 19
Subject: Final Verdict
Date: October 21, 2021

XIV HIS MICA 2021

Author(s): Alexis Gallegos, Dolores Torres, and Aurora Torres

I hereby write to you to inform you that the work entitled “**Feature Subset Selection in Electroencephalographic signals using typical testors**” with ID 19, submitted for the “**XI Workshop of Hybrid Intelligent Systems**” to be held on **October 25-26, 2021** during the MICA 2021 Workshops day, **was Accepted with Observations**, and will be published in a special volume of the journal Research in Computing Science ISSN 1870-4069, in accordance with the following observations:

Reviewer 1 Verdict: Accepted with Observations
Recommendations:
<ul style="list-style-type: none"> •The article “HIS2021_paper_19” should be rewritten in tables and the reference section. In addition, only one line break is missing in the text (above Table 1). •Furthermore, authors should reduce the plagiarism score. •The reference format should be corrected. •Tables format should be corrected, Rows and captions. •The article is well supported by the literature. •The articles present research with conclusive results.
Reviewer 2 Verdict: Accepted with Observations
Recommendations:
It is necessary to improve the figures and make a more detailed multivariate analysis in order to better understand the main objective of the research.
Reviewer 3 Verdict: Accepted with Observations
Recommendations:
Authors must make the changes indicated in the reviews.

If you have been accepted, we ask you to pay special attention to the dates and requirements published in the page <http://www.edgarcossio.mx/his2021/>

The publication fee amount for accepted papers is \$1,000 MXN. Please transfer the fee to any of the following accounts in Mexican pesos to:

Bank: BBVA Bancomer, **Account:** 0194625285, **CLABE:** 012180001946252858, **Beneficiary:** Sociedad Mexicana de Inteligencia Artificial, A.C.

or

Bank: BANAMEX, **Branch:** 4152, **Account:** 0194825, **CLABE:** 002180415201948254, **Beneficiary:** Sociedad Mexicana de Inteligencia Artificial, A.C.

As payment details please use:





Article ID: 19
Subject: Final Verdict
Date: October 21, 2021

Workshop authors: "MICAI 2021 workshop (workshop abbreviation) paper (paper title or first several words of it)", for example: "MICAI 2021 workshop HIS paper Solving the capacitated vehicle routing problem in a shared bicycle system of a smart city".

If you pay from abroad, please make sure that the complete fee is deposited to our account; i.e., if there is any transfer fee, please add it to your payment.

Upon payment, please send a message at martin.montes@upa.edu.mx, with the subject "Payment MICAI 2021 paper (your paper ID)", and attach the payment proof (either a receipt generated by the online system or a scanned image of a physical receipt). In the body of the message please indicate the paper number and title.

Thanking you for your valuable attention to this letter, I send you cordial and respectful greetings.

Dr. Martin Montes Rivera

CHAIR

XIV Workshop of Hybrid Intelligent Systems



A.8 Feature selection in electroencephalographic signals using a multicriteria decision analysis method

A. E. Gallegos Acosta, M. D. Torres Soto, A. Torres Soto, E. E. Ponce de León Sentí, and C. A. Ochoa Ruíz Zezzatti, “*Feature Selection in Electroencephalographic Signals Using a Multicriteria Decision Analysis Method.*” *Innovation and Competitiveness in Industry 4.0 Based on Intelligent Systems*, Springer. (En proceso de publicación).

INDICES: Conference Proceedings Citation Index (CPCI, part of Clarivate Analytics’ Web of Science), EI Engineering Index (Compendex and Inspec databases), ACM Digital Library, DBLP, Google Scholar, IO-Port, MathSciNet, Scopus, ZentralBlatt Math

NOTA: En proceso de publicación

Resumen

In recent years, industry 4.0 has promoted the rise of new technologies and devices that generate and collect data both in industry and in everyday life. As a result, there is a new challenge of creating robust tools that facilitate the analysis of this information. Feature selection allows the efficient extraction of features that describe objects or phenomena, by removing distractors and redundant information. Thus, classification and decision-making models can be created with stable representations. In this chapter, a set of typical testors was extracted from a database with motor imagery EEG signals employing the testor theory, an approach to feature selection. A typical testor is the smallest possible combination of features that allow objects to be differentiated belonging to different classes. The purpose of this chapter is to select the typical testor with the best performance in an ANN classifier employing TOPSIS, a multicriteria decision analysis method.

Palabras clave

TOPSIS, EEG Signals, Artificial Neural Network, Typical Testors Theory, Mo-tor Imagery, Industry 4.0



Dear Alexis Gallegos,

We are pleased to inform you that your manuscript,

Paper ID: 7148
 Title: Feature Selection in Electroencephalographic Signals Using a Multicriteria Decision Analysis Method
 Authors: *Alexis Gallegos, María Dolores Torres Soto, Aurora Torres Soto, Eunice Esther Ponce De León Sentí, Alberto Ochoa-Zezzatti.

has been accepted for publication in Innovation and Competitiveness in Industry 4.0 Based on Intelligent Systems. The reviewers' reports have been attached at the bottom of this email.

Please upload a final, camera-ready version as approved by Editor:
<https://escripts.eai.eu/paper/lists?accepted>

Please make sure that your paper follows the [instructions](#) and is in the correct [EAI Endorsed Transactions template](#). A manuscript in a different template will be sent back for correction.

After signing the copyright agreement we will proceed with the publication of your article.

Thank you for submitting your work to Innovation and Competitiveness in Industry 4.0 Based on Intelligent Systems.

For your efforts as an Author, you receive 10 points based on the average review score of your submission as evaluated by Reviewers and supervised by the Handling Editor. These points count toward your EAI Index.

EAI Index represents a revolution in recognizing excellence in research fairly and transparently, and it is a key element in annual nominations for the member ranks of EAI Fellows, Distinguished Members, and Senior Members. You can view your current EAI Index in your [user profile](#) at any time and gain more points by volunteering in other EAI conferences and journals, or by submitting papers to these research venues:

- Bid to Review recently submitted papers in [Community Review](#)
- See [open positions](#) in conferences and journals
- Explore [conferences](#) and [journals](#) open for submission

To learn more about EAI's transparent research recognition program, please visit the [EAI website](#).

Best Regards,

Publication Department | European Alliance for Innovation
publications@eai.eu | www.eai.eu

Reviewers comments:
*** REFEREE 3 REPORT ***

=====

** Below you can find comments on each criterions **

1 . Novelty of the contribution

...

2 . Innovation impact of the proposed concept

...

3 . Technical content and correctness of the contribution

...

4 . Importance of the manuscript for the thematic area

...

5 . Implementation potential of the proposed concept

...

6 . Completeness of the references

...

7 . Quality of the writing

...

** General comments by referee 3 to Author**

Excellent work, very innovative, and well designed! Congratulations.

*** REFEREE 2 REPORT ***

=====

**** Below you can find comments on each criterions ****

1 . Novelty of the contribution

...

2 . Innovation impact of the proposed concept

...

3 . Technical content and correctness of the contribution

...

4 . Importance of the manuscript for the thematic area

...

5 . Implementation potential of the proposed concept

...

6 . Completeness of the references

...

7 . Quality of the writing

...

**** General comments by referee 2 to Author****

The recommendations from previous review round were attended, however some images needs to be improved, for example Fig. 4 & Fig. 6 have quality resolution problems.

***** REFEREE 1 REPORT *****

=====

**** Below you can find comments on each criterions ****

1 . Novelty of the contribution

It is good work. A small recommendation is to do a deep literature review on MCDM methods

2 . Innovation impact of the proposed concept

The paper represents a good innovation due to the field involved in application study.

3 . Technical content and correctness of the contribution

The paper addressed a good numerical case to explain the proposal.

4 . Importance of the manuscript for the thematic area

The implementation to explore new applications

5 . Implementation potential of the proposed concept

The paper conducted to replicate the proposal for new problem

6 . Completeness of the references

Good

7 . Quality of the writing

It represent a good material

** General comments by referee 1 to Author**

It is good work. A small recommendation is to do a deep literature review on MCDM methods

A.9 Toma de decisiones en testores típicos de señales EEG con intención de movimiento

A. E. Gallegos Acosta, M. D. Torres Soto, A. Torres Soto, and E. E. Ponce de León Sentí, "Toma de decisiones en testores típicos de señales EEG con intención de movimiento". Memorias del Congreso Investigación en el Posgrado, 2022.

TOMA DE DECISIONES EN TESTORES TÍPICOS DE SEÑALES EEG CON INTENCIÓN DE MOVIMIENTO, ALEXIS GALLEGOS, AURORA TORRES SOTO.

INTRODUCCIÓN: Las interfaces cerebro-computadora (BCI) han extendido su espectro de aplicación, desde contextos médicos hasta lúdicos. Estos sistemas permiten traducir pensamientos en comandos para la máquina. Las señales EEG son complejas por la información que se puede extraer. Para ello, se propone el análisis de testores para reducir la dimensionalidad en el número de canales que registran la actividad cerebral.

OBJETIVO: Aplicar el método TOPSIS para seleccionar de un conjunto de testores típicos, extraídos de una base de datos que describe señales EEG con intención de movimiento, aquel que permita un mejor desempeño de clasificación en modelo de red neuronal artificial.

METODOLOGÍA: El primer paso fue la extracción señales EEG con intención de movimiento (abrir y cerrar mano) de seis sujetos de prueba. El segundo constó del preprocesamiento de las señales. Como tercer paso, se obtuvo un conjunto de testores típicos (TT) aplicando el enfoque lógico-combinatorio de la teoría de testores. En el cuarto paso se implementó una red neuronal artificial. El quinto paso aplicó el método TOPSIS para seleccionar el TT con mejor rendimiento de clasificación.

RESULTADOS: Como resultado, se contó con una base de datos compuesta por 12,190 registros de abrir mano y 11,656 de cerrar mano. Ambos descritos por 14

electrodos con mediciones en μV . En el preprocesamiento se observó una alta correlación entre las 14 características, sin embargo, existe una alta variación entre sus desviaciones estándar. Por tanto, se optó por trabajar con datos normalizados. Para el tercer paso, se obtuvo un conjunto de 5 testores típicos, los cuales reducen el número de características que describen las señales. Cada testor típico fue utilizado para clasificar señales en un modelo de red neuronal artificial obteniendo métricas como exactitud, precisión positiva y negativa y la tasa de falsos positivos y negativos. Dichas métricas se utilizaron como entrada para el análisis TOPSIS. Este análisis permitió conocer el testor típico con mejor rendimiento de clasificación y, a su vez, un ranking de la mejor alternativa a la peor.

CONCLUSIÓN: TOPSIS es un enfoque para la toma de decisiones multicriterio que permite la evaluación de alternativas que pueden involucrar variables cuantitativas y cualitativas. En este caso, permitió decidir de un conjunto de testores típicos, aquel con mejor desempeño en clasificación. Gracias a ello, se pueden construir herramientas como las BCI con la información más determinante de acuerdo con un objetivo específico. En este caso, la intención de movimiento de abrir y cerrar la mano derecha.

BIBLIOGRAFÍA: J. Ruiz Shucloper, E. Alba Cabrera, & M. Lazo Cortés, "Introducción a la Teoría de Testores." Departamento de Ingeniería Eléctrica, CINVESTAV-IPN, 1995. V. Yadav, S. Karmakar, P. P. Kalbar, and A. K. Dikshit, "PyTOPS: A Python based tool for TOPSIS," SoftwareX, vol. 9, 2019.

Universidad Autónoma de Aguascalientes
Doctorado en Ciencias Aplicadas y Tecnología
alexisedm@gmail.com
Jardines de Santa Elena
4491020146

Tutor: Doctora MARÍA DOLORES TORRES SOTO

