

Uso de SVM en señales EEG para la clasificación de comandos mentales y su aplicación para el control de dispositivos móviles

Vanessa Isabel Arellano-Serna, Aurora Torres-Soto,
María Dolores Torres-Soto

Universidad Autónoma de Aguascalientes,
Ciudad Universitaria,
México

{al227437, aurora.torres, dolores.torres}@edu.uaa.mx

Resumen. En el siglo XX surgieron dos elementos fundamentales: las máquinas de soporte vectorial (SVM) y las interfaces cerebro-computador (BCI). Las SVM, algoritmos de aprendizaje supervisado, han evolucionado para resolver problemas no lineales, mientras que las BCI buscan la comunicación entre cerebro y computadora. Este estudio propone una solución que integra SVM para clasificar comandos mentales en señales electroencefalográficas (EEG) para el control de dispositivos móviles. Se utilizó la diadema Emotiv Epoc+ de 14 canales para la captura de datos EEG, seguida de la extracción de características mediante el método de patrón espacial común (CSP). Los resultados muestran altas precisiones de clasificación utilizando SVM con kernel RBF, los cuales se encuentran en un promedio de 0.94, 0.95 y 0.95 en las métricas de precisión, recobro y F1 respectivamente. Se propone una definición de comandos mentales y se discute su relevancia en el contexto de las BCI. La arquitectura del sistema propuesto incluye Subapase, Heroku, ThreeJS y Flutter. Este estudio promueve la inclusividad eliminando el esfuerzo físico-motor para la interacción con la tecnología, y representa un paso hacia un cambio de paradigma en la interacción con el mundo digital.

Palabras clave: Señales EEG, SVM, comandos mentales, dispositivos móviles.

Use of SVM on EEG Signals for Mental Command Classification and its Application for Mobile Device Control

Abstract. The 20th century saw the emergence of two fundamental elements: support vector machines (SVM) and brain-computer interfaces (BCI). SVM, which are supervised learning algorithms, have evolved to solve nonlinear problems, while BCI seek brain-computer communication. This study proposes a solution that integrates SVM to classify mental commands found in electroencephalographic (EEG) signals for mobile device control. The 14-channel Emotiv Epoc+ headset was used for EEG data capture, followed by feature extraction using the common spatial pattern (CSP) method. The results show high classification accuracies using SVM with RBF kernel, which

average 0.94, 0.95 and 0.95 on precision, recall and F1 metrics respectively. A definition of mental commands is proposed and their relevance in the context of BCI is also discussed. The proposed system architecture includes Subapase, Heroku, ThreeJS and Flutter. This study promotes inclusivity by eliminating physical-motor required in daily technology usage, and represents a step towards a paradigm shift on how to interact with the digital world.

Keywords: EEG signals, SVM, mental commands, device control.

1. Introducción

A partir del siglo XX surgieron dos elementos fundamentales para el presente trabajo: las máquinas de soporte vectorial (SVM) y las interfaces cerebro computador (BCI). Las primeras surgen como un algoritmo de aprendizaje supervisado utilizado en una gran variedad de problemas de clasificación y regresión. Su objetivo es maximizar el hiperplano que separa a las clases que se desean clasificar y aunque su funcionamiento fue pensado para problemas lineales, este algoritmo ha evolucionado y se apoya de diferentes funciones de kernel para transformar sus características, haciendo así a la SVM más flexible y funcional para problemas no lineales [10, 11].

Por otro lado, BCI es una tecnología que busca la comunicación, como su nombre lo señala, entre cerebro y computadora. Este proceso de intercambio de información puede ser unidireccional (cerebro a computador o computador a cerebro), o bidireccional (cerebro a computador y computador a cerebro) [13]. Uno de los principales métodos de captura de datos para esta tecnología, es la captura de señales electroencefalográficas, una técnica no invasiva para el registro de la actividad eléctrica del cerebro. Estas señales pueden adquirir luego una interpretación, por ejemplo, se pueden convertir en información acerca de si el usuario está relajado, en hiperfoco o distraído.

Sin embargo, las inferencias no se limitan al estado mental en el que se encuentra el usuario; esta tecnología también se ha utilizado para captar la intención de movimiento del usuario y su aplicación se ha enfocado principalmente en trabajos biomédicos [13]. Ahora mismo el campo de los sistemas BCI se encuentra en una etapa crucial, ya que el área ha resuelto situaciones cotidianas, una óptica a la que pertenece este trabajo y dentro de la cual los algoritmos de aprendizaje máquina han protagonizado como herramientas para la clasificación de intenciones dentro de las señales EEG.

Aún se enfrentan desafíos, como la entropía de las señales de un mismo sujeto dependiendo del tiempo y espacio en que se encuentre, sin embargo, las máquinas de soporte vectorial (SVM) se han popularizado dentro de la clasificación de estas señales debido a que son capaces de manejar datos de alta dimensionalidad y han presentado precisiones sobresalientes respecto de otros enfoques en problemas multiclase y manejo de entropía [16, 6]. Este estudio tiene como objetivo la búsqueda de promover una mayor y más amplia inclusión eliminando la necesidad de un esfuerzo físico-motor para la interacción con la tecnología, al basarse únicamente en comandos mentales del usuario. Además se busca formar parte de los primeros pasos hacia el cambio de paradigma en la forma en que se interactúa con el mundo digital.

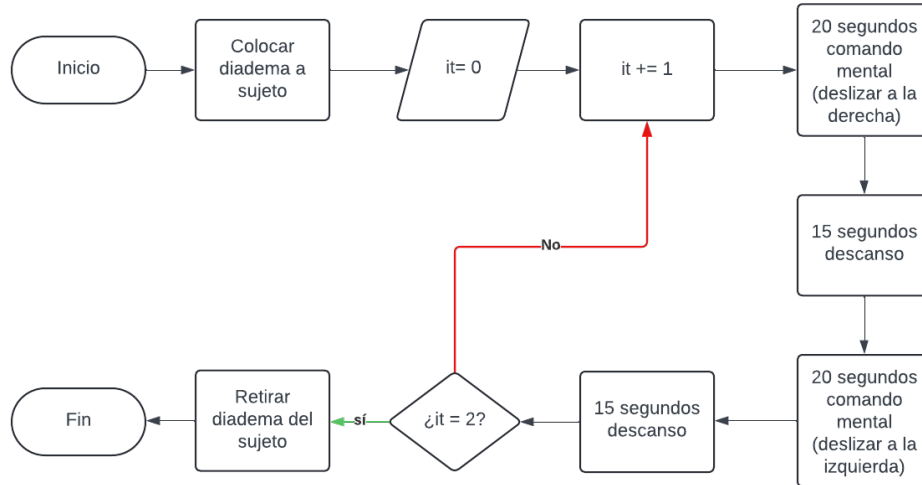


Fig. 1. Diagrama explicativo del proceso de captura de datos.

Se propone una solución que integra el uso de las máquinas de soporte vectorial aplicadas para la clasificación de comandos mentales obtenidos de señales EEG para el control de dispositivos móviles. Para la adquisición de datos EEG se utiliza la diadema Emotiv Epoc+ de 14 canales, seguida de la limpieza de los datos y extracción de características por medio del método CSP (Common Spatial Pattern). Para la demostración visual del funcionamiento de la clasificación de señales EEG, se desarrolló un producto con interfaz gráfica para dispositivos móviles, controlado de manera asíncrona por medio de comandos mentales, para esto se generó una API en Python la cual se integró con una aplicación en Flutter.

En la sección 2. Conceptos principales, se presentan las definiciones más importantes para el entendimiento del trabajo. Seguido por 3. Metodología, donde se describe desde los materiales requeridos, la selección de la población de estudio, el proceso de captura de datos, extracción de características y clasificación. Los hiperparámetros utilizados, resultados y diseño de la arquitectura del sistema pueden ser encontrados en la sección 4. Resultados. Por último en 5. Conclusiones y discusión se destaca la posible relación del método de extracción de características utilizado con el buen desempeño del modelo.

2. Conceptos principales

Esta sección presenta brevemente los conceptos principales utilizados dentro de este trabajo.

1. **SVM.** Tipo de algoritmo de aprendizaje supervisado utilizado principalmente para clasificación y regresión. El objetivo de las SVM es encontrar el hiperplano óptimo que maximice la separación entre las clases en un espacio multidimensional, donde cada punto de datos se representa como un vector [8].




Fig. 2. Representación del impacto de distintos valores de C y γ como mapa de calor [15].

2. **CSP**. Método de extracción de características comúnmente utilizado para procesamiento de señales de clasificación motora, busca de amplificar la variabilidad de los datos entre clases y minimizarla en la misma clase [9].
3. **RBF**. Función kernel que mide la similitud entre pares de puntos de datos basándose en su distancia en el espacio de características [7].
4. **API**. Mecanismo que permite a dos componentes de software comunicarse entre sí mediante un conjunto de definiciones y protocolos [1].

3. Metodología

3.1. Materiales

Para la obtención de señales EEG, se utiliza la diadema multicanal Emotiv EPOC+, creada para la investigación del cerebro humano y su aplicación en sistemas BCI; cuenta con catorce nodos que permiten una lectura de una amplia área cerebral. Las almohadillas de la diadema deben ser saturadas con solución salina para lograr una buena conexión y recepción de los datos. El dispositivo es acompañado con Emotiv Launcher, un software del fabricante EMOTIV, que permite visualizar la calidad de las señales contacto que se está obteniendo de la diadema con el cuero cabelludo del usuario.

Tabla 1. Hiperparámetros utilizados en la SVM y resultados obtenidos por clase.

Clase	Kernel	Gamma	C	Precisión	recobro	F1
0 (izquierda)				0.96	0.93	0.95
1 (descanso)	RBF	0.15	2	0.94	0.94	0.94
2 (derecha)				0.95	0.98	0.96

3.2. Población de estudio

Para la selección de la población de estudio, se establecieron diversos criterios de inclusión y exclusión, con el fin de controlar en la medida de lo posible las variables que podrían impactar en la entropía de las señales capturadas. Estos criterios son detallados a continuación:

1. **Género.** Con el fin de impulsar la participación de las mujeres en los proyectos del área STEM y buscando disminuir el sesgo de género histórico en la elección de sujetos de prueba, fueron seleccionadas únicamente sujetos de prueba del sexo femenino.
2. **Ausencia de evento cerebrovascular.** Se excluyeron sujetos que hubieran experimentado algún accidente o enfermedad cerebrovascular.
3. **Edad.** Se seleccionaron sujetos de entre 18 y 30 años de edad.
4. **Compromiso de asistencia.** Se requirió que los sujetos de prueba pudieran comprometerse a asistir a todas las sesiones de captura de datos y pruebas, garantizando así la integridad y la coherencia de los datos recopilados a lo largo del estudio.

La selección de sujetos se realizó mediante un proceso de reclutamiento activo, que incluyó la difusión de información sobre el estudio en redes sociales y sociedades de alumnos de la institución. A los individuos interesados se les envió un formulario inicial para determinar su elegibilidad de acuerdo con los criterios mencionados anteriormente. Finalmente, como primera aproximación se seleccionaron dos mujeres de 19 y 22 años, además se obtuvo el consentimiento informado de ambas participantes antes de su inclusión en el estudio.

3.3. Descripción de la captura de datos

Los datos capturables se enfocaron en la intención de dos comandos mentales principales: 1) mover un objeto a la izquierda y 2) mover un objeto a la derecha, entre los comandos, se encuentra un tiempo de descanso que es capturado y etiquetado dentro del set de datos. En este contexto se desea definir el concepto de comando mental, de tal forma que se adapte de manera precisa a la actividad cerebral realizada; la aclaración del concepto de comando mental es relevante e importante, ya que en múltiples publicaciones anteriores se ha utilizado de diversas formas sin exponer una definición clara que le permita reconocerse como una actividad cerebral específica.

Tabla 2. Resultados de validaciones cruzadas (5 y 10 subsegmentos).

No. subconjuntos	Puntaje (x/1)										\bar{x}	
	1	2	3	4	5	6	7	8	9	10		
5	0.94	0.93	0.93	0.94	0.94							0.9406
10	0.94	0.94	0.94	0.94	0.93	0.94	0.94	0.94	0.94	0.94	0.95	0.9453

Hoy en día la innovación y crecimiento tecnológico y científico requiere discernir de forma concreta las diferentes actividades mentales aplicadas en los sistemas BCI. A continuación se presenta una propuesta para la definición de comando mental, de igual manera será el utilizado para el presente trabajo.

Definición 1 (Comando mental). Se entiende como comando mental, la actividad cerebral orientada a utilizar exclusivamente la intención del usuario como orden para controlar un sistema BCI. Es importante diferenciar la definición otorgada con otras clasificaciones de actividades mentales como lo es la imaginación motora.

La diferencia radica en que los comandos mentales no requieren la imaginación de un movimiento físico-motor [14], ya que esto podría dificultar su uso para individuos con discapacidades de este tipo; por otra parte un comando mental se concentra en imaginar con intención la tarea que se desea que el sistema realice.

Debido a la gran entropía que presentan las señales EEG de un mismo individuo dependiendo de la hora o el lugar de la toma de datos, se decidió capturar en un mismo momento todos los datos de un individuo, pudiendo así tener la menor entropía posible en los registros de datos de un solo sujeto de prueba.

Para el proceso de captura de datos, se lleva a cabo un cronometrado de tiempo, donde se le indica al sujeto de prueba que piense en un comando mental durante una X cantidad de tiempo, después le sigue un descanso con una duración Y para luego pensar en otro comando mental durante X tiempo. Además se decidió agregar un conjunto de datos aleatorios donde el sujeto de prueba se encuentre realizando una actividad común que no precise de un esfuerzo significativo.

En la Figura 1 se presenta un diagrama explicativo del proceso de la captura de los datos, donde se observa que cada sesión de grabación constó de dos iteraciones en las que el participante imaginaba por 20 segundos a un objeto mostrado en pantalla deslizándose a la derecha, seguidos por 15 segundos de descanso para después imaginar durante 20 segundos el deslizamiento a la izquierda, por último se graba el último descanso de 15 segundos.

3.4. Extracción de características: Patrón espacial común (CSP)

En busca de amplificar la variabilidad de los datos entre clases y minimizarla en la misma clase, se aplica el método CSP. Este método ha sido utilizado previamente en el área de sistemas BCI como método de extracción de características dentro de la imaginación motora por medio de filtrados espaciales. El objetivo del CSP es encontrar la matriz de proyección W , que funciona como matriz de transformación para proyectar los datos originales desde el espacio de las señales de entrada a un nuevo espacio donde las clases de interés se vuelven linealmente separables.




Fig. 3. Curva Precisión-Recobro representativa para la clasificación de comandos mentales con modelo SVM.

Esta transformación se logra encontrando los vectores propios que maximizan la varianza entre clases y minimizan la varianza dentro de cada clase. Este objetivo se puede expresar como se hace en (1) lo que corresponde a un problema de optimización [9]:

$$\max_W \frac{(W^T S_b W)}{(W^T S_w W)}, \quad (1)$$

donde:

S_b : Representa la matriz de covariancia entre clase.

S_w : Representa la matriz de covarianza interclase.

3.5. Clasificación: Máquinas de soporte vectorial (SVM)

Las SVM son modelos de aprendizaje supervisado que se utilizan ampliamente en problemas de clasificación y regresión. La ventaja principal de las SVM radica en su capacidad para manejar eficientemente conjuntos de datos de alta dimensionalidad y no lineales. Esto las hace especialmente adecuadas para el análisis de señales biológicas, como las señales EEG, que frecuentemente exhiben una alta dimensionalidad y una estructura no lineal [8].




Fig.4. Matriz de confusión del modelo SVM para la clasificación de comandos mentales. La mayoría de los datos se concentran en la diagonal principal, esto manifiesta que las clases asignadas por el clasificador fueron mayormente correspondientes a la clase verdadera.

El objetivo de las SVM es encontrar el hiperplano con el mayor margen posible que separe las clases de manera lineal, facilitando así la distribución de nuevos datos de entrada en su clase correspondiente, estos datos son representados como un vector n -dimensional [5]. Expresado de forma matemática, las SVM funcionan de la siguiente manera. Dado un conjunto de datos de entrenamiento $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ donde x_i es un vector de características y y_i es la etiqueta de clase correspondiente, una SVM lineal busca encontrar el hiperplano de la siguiente forma:

$$w^T x + b = 0, \tag{2}$$

donde w es el vector de pesos y b es el término de sesgo. Dado un nuevo punto de datos x , la SVM predice la clase de la siguiente manera:

$$\text{Clase}(x) = \begin{cases} 1 & \text{si } w^T x + b \geq 0, \\ -1 & \text{si } w^T x + b < 0. \end{cases} \tag{3}$$

En el caso de que los datos no sean linealmente separables, se puede utilizar una SVM no lineal que mapea los datos a un espacio de características de mayor dimensión utilizando una función kernel. En este caso, la SVM se vería así:

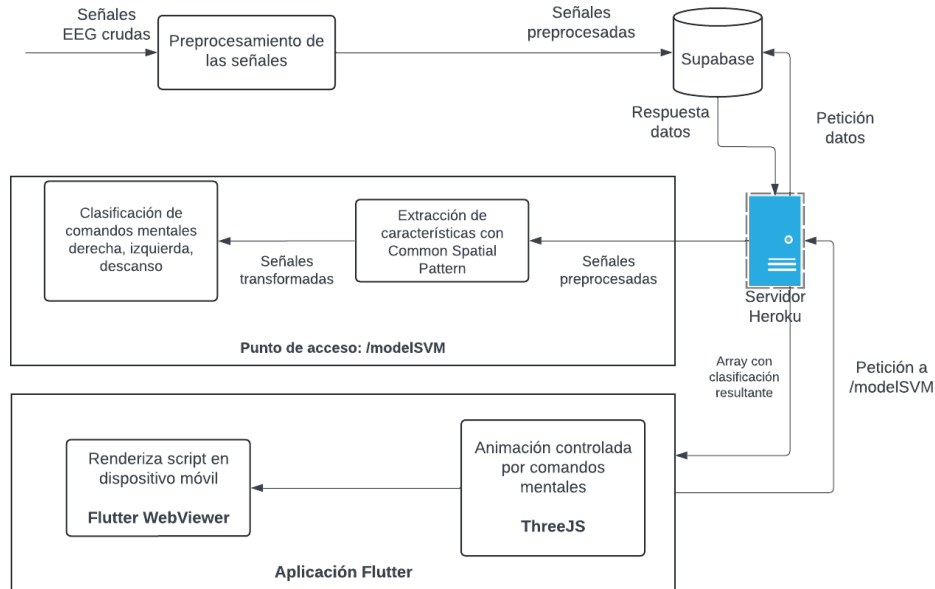


Fig. 5. Arquitectura del sistema desarrollado.

$$\text{Clase}(x) = \begin{cases} 1 & \text{si } \sum_{i=1}^n \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}) + b \geq 0, \end{cases} \quad (4)$$

$$\text{Clase}(x) = \begin{cases} -1 & \text{si } \sum_{i=1}^n \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}) + b < 0, \end{cases} \quad (5)$$

donde $K(x_i, x)K(x_i, x)$ es la función kernel que mide la similitud entre los puntos x_i y x , e α_i son los coeficientes de Lagrange obtenidos durante el entrenamiento del modelo. Debido a la gran cantidad de registros analizados dentro de este estudio, así como también al desempeño mostrado por las SVM en trabajos previos, se decidió llevar a cabo la clasificación de comandos mentales por medio de este algoritmo.

Uno de los aspectos fundamentales dentro de este algoritmo es la selección del kernel a utilizar, ya que este determina cómo se mapean los datos de entrada en un espacio dimensional más alto, donde es más probable que sean linealmente separables [12]. Con el objetivo de clasificar de forma precisa los comandos mentales registrados, se optó por el uso de un kernel de función de base radial (RBF por sus siglas en inglés) debido a su notoria aportación al desempeño del algoritmo frente a señales biométricas como las EEG [2].

3.6. Kernel de función de base radial (RBF)

Al seleccionar un kernel RBF se deben considerar un par de parámetros que tienen la capacidad de optimizar el desempeño del modelo, estos son C y γ . Por un lado C se comporta como un parámetro de regularización de la SVM, así pues, controla el balance




Fig. 6. Capturas de pantalla de la aplicación desarrollada para la visualización del funcionamiento del modelo. En las imágenes, el cubo responde al comando 'derecha'.

entre la maximización del margen y la minimización del error de clasificación en el conjunto de entrenamiento; este mismo penaliza a las clasificaciones incorrectas por lo que un valor alto de C permite que el modelo clasifique más puntos de entrenamiento correctamente incluso si esto significa generar un margen de separación más pequeño entre clases. De manera contraria, un bajo valor para C representa la priorización de un margen más grande aún cuando la precisión de la clasificación de los puntos de entrenamiento se vea comprometida [15].

Definir γ requiere de cuidado para evitar un sobreajuste o un subajuste, ya que este controla la forma en que se propaga la influencia de un punto de datos individual. Especificando, un valor pequeño de γ resulta en fronteras de decisión y modelos más suavizados, lo que se traduce a una transición más gradual entre las regiones clasificadas como una clase u otra y como es de esperarse un valor alto de γ figura el efecto contrario para el modelo [15]. En la Figura 2 se logra visualizar cómo entre menor es C , mayor es el margen que divide a las clases y un menor γ genera regiones de clase más amplias y suavizadas.

4. Resultados

Lograr una clasificación precisa de señales EEG mediante algoritmos de inteligencia artificial sigue siendo un campo de estudio al día de hoy. Este trabajo propone la implementación del método CSP para extracción de características, cuya salida será clasificada por medio de una máquina de soporte vectorial.

En esta sección se hablará de los hiperparámetros seleccionados para el modelo, los resultados de precisión, F1 y recobro obtenidos, así como también se mostrará la arquitectura del sistema desarrollado para la aplicación de esta clasificación en dispositivos móviles.

4.1. Clasificación: Hiperparámetros y resultados SVM

Una vez que la petición al servidor para recuperar los datos de entrada es ejecutada, el conjunto de datos se divide en columnas de atributos y la columna con las etiquetas de clasificación ($X =$ atributos, $Y =$ etiquetas). Seguido de esto, se comienza la extracción de características, donde se calculan las matrices de covarianza para cada clase, calculando entonces la proyección CSP. Esta proyección debe ser aplicada a X , con el fin de obtener los datos transformados que representan los datos de entrada para nuestra SVM (X_{csp}).

Naturalmente, el conjunto de datos es dividido en datos de entrenamiento y prueba, asignando el 80 % y 20 %. Dado que los datos fueron procesados por el método CSP que busca la maximización de variabilidad entre clases y minimización de variabilidad entre datos de una misma clase, se experimentó con un valor de $C = 2$ relativamente alto para el modelo SVM, mientras que para el hiperparámetro γ se buscó un valor pequeño que ampliara el área de las clases.

La Tabla 1 muestra los hiperparámetros utilizados y los resultados obtenidos por el modelo. Una curva de precisión-recobro permite evaluar el rendimiento de un modelo de clasificación, especialmente cuando las clases están desbalanceadas. Esta curva muestra cómo varía la precisión del modelo en función del recobro (también conocido como sensibilidad o tasa de verdaderos positivos) al cambiar el umbral de decisión del clasificador.

1. **Precisión.** La precisión se refiere a la proporción de instancias clasificadas correctamente como positivas entre todas las instancias clasificadas como positivas por el modelo. Una alta precisión indica que el modelo no clasifica erróneamente muchas instancias como positivas [3].
2. **Recobro.** El recobro indica la proporción de instancias positivas que fueron clasificadas correctamente como positivas por el modelo. Un alto recobro significa que el modelo identifica correctamente la mayoría de las instancias positivas [4].

En la Figura 3. se presenta la curva de precisión-recobro obtenida del modelo construido en esta investigación. Para verificar que no se trata de un modelo sobreajustado, se sometió también a la técnica de validación cruzada, La Tabla 2 muestra los resultados obtenidos. Con el fin de visualizar el desempeño del modelo, se opta por graficar una matriz de confusión, ya que logra proporcionar un resumen claro de la clasificación realizada por el modelo en comparación con las clasificaciones reales. Las filas representan a las clases reales y las columnas a las clases propuestas por el clasificador, se busca que la diagonal principal de la matriz destaque. En la Figura 4 se muestra la matriz de confusión obtenida con los resultados de las predicciones del modelo.

4.2. Arquitectura del sistema

Uno de los principales aportes del presente artículo es la conexión del modelo desarrollado con una aplicación funcional para dispositivos Android, el cual es capaz de controlar un objeto de forma asíncrona con base a las señales previamente clasificadas. La aplicación fue probada en un celular de gama baja con las siguientes características:

- **Memoria RAM.** 3GB.
- **Memoria interna.** 32GB.
- **Procesador.** Octa core.
- **Marca.** VIVO.
- **Modelo.** Y01.
- **Sistema operativo.** Funtouch OS.

La planificación de la arquitectura de los sistemas BCI constituye una fase crucial en su desarrollo. Para adaptar este proyecto a dispositivos móviles, se incorporaron múltiples tecnologías, las cuales se describen a continuación.

- **Supabase.** Para el almacenamiento de los .csv contenidos de las señales EEG capturadas.
- **Heroku.** Utilizado como host para la API.
- **ThreeJS.** Para la animación del objeto a controlar con comandos mentales.
- **Flutter.** Para renderizar la aplicación en un dispositivo móvil.

La Figura 5. muestra la arquitectura diseñada para la comunicación entre la API, modelo e interfaz del sistema desarrollado. En la Figura 6. se presentan capturas de pantalla de la aplicación ejecutándose en un dispositivo Android.

5. Conclusiones y discusión

La aplicación del método CSP para la extracción de características parece potencializar el desempeño de las máquinas de soporte vectorial clasificando señales EEG, dando resultados mayores a 0.9/1 en distintos tipos de evaluación del modelo (precisión, recobro, F1). Trabajos del autor anteriores donde no se aplica CSP reducen a un desempeño promedio de 0.7 en precisión. Se considera que debido a que el método CSP amplía la variabilidad entre clases, se da la oportunidad de probar con hiperparámetros del modelo SVM no convencionales o que comúnmente llevan a sobreajustes o subajustes.

Debido a la creciente importancia y diversificación de los sistemas BCI se invita a la comunidad académica a definir y diferenciar actividades cerebrales que son comúnmente englobadas a otras, pues las aplicaciones de este tipo de tecnología crece día a día, y estos conceptos habilitan nuevos campos de investigación, diseño e implementaciones de sistemas BCI.

Cabe mencionar que si bien se presentó una propuesta para la arquitectura del sistema, el foco de atención se dirigió al procesamiento y clasificación de los datos, por lo que, aunque resultó funcional, se considera que el desempeño de la aplicación se podría ver beneficiada por un rediseño futuro de la arquitectura propuesta.

Referencias

1. Amazon Web Services: ¿Qué es una interfaz de programación de aplicaciones (API)? (2024) aws.amazon.com/es/what-is/api
2. Bousseta, R., Tayeb, S., Ouakouak, I. E., Gharbi, M., Regragui, F., Himmi, M. M.: EEG efficient classification of imagined hand movement using RBF kernel SVM. In: 11th International Conference on Intelligent Systems: Theories and Applications, vol. 113, pp. 1–6 (2016) doi: 10.1109/sita.2016.7772278
3. C3.ai: Precision in machine learning (2024) c3.ai/glossary/machine-learning/precision/
4. C3.ai: Recall in machine learning (2024) c3.ai/glossary/machine-learning/recall/
5. Chatterjee, R., Bandyopadhyay, T.: EEG based motor imagery classification using SVM and MLP. In: 2nd International Conference on Computational Intelligence and Networks, pp. 84–89 (2016) doi: 10.1109/cine.2016.22
6. Dokare, I., Kant, N.: Performance analysis of SVM, kNN and BPNN classifiers for motor imagery. International Journal of Engineering Trends and Technology, vol. 10, no. 1, pp. 19–23 (2014) doi: 10.14445/22315381/ijett-v10p205
7. Eskandar, S.: Introduction to RBF SVM: A powerful machine learning algorithm for non-linear data. Medium (2023) medium.com/@eskandar.sahel/introduction-to-rbf-svm-a-powerful-machine-learning-algorithm-for-non-linear-data-1d1cfb55a1a
8. Ganaie, M. A., Tanveer, M., Jangir, J.: EEG signal classification via pinball universum twin support vector machine. Annals of Operations Research, vol. 328, no. 1, pp. 451–492 (2022) doi: 10.1007/s10479-022-04922-x
9. Gaur, P., Gupta, H., Chowdhury, A., McCreddie, K., Pachori, R. B., Wang, H.: A sliding window common spatial pattern for enhancing motor imagery classification in EEG-BCI. IEEE Transactions on Instrumentation and Measurement, vol. 70, pp. 1–9 (2021) doi: 10.1109/tim.2021.3051996
10. Kawala-Sterniuk, A., Browarska, N., Al-Bakri, A., Pelc, M., Zygarlicki, J., Sidikova, M., Martinek, R., Gorzelanczyk, E. J.: Summary of over fifty years with brain-computer interfaces—a review. Brain Sciences, vol. 11, no. 1, pp. 43 (2021) doi: 10.3390/brainsci11010043
11. MathWorks: Introducción a support vector machine (SVM). Support Vector Machine (2024) la.mathworks.com/discovery/support-vector-machine.html
12. Mustafa-Abdullah, D., Mohsin-Abdulazeez, A.: Machine learning applications based on SVM classification a review. Qubahan Academic Journal, vol. 1, no. 2, pp. 81–90 (2021) doi: 10.48161/qaj.v1n2a50
13. Peksa, J., Mamchur, D.: State-of-the-art on brain-computer interface technology. Sensors, vol. 23, no. 13, pp. 6001 (2023) doi: 10.3390/s23136001
14. Saibene, A., Caglioni, M., Corchs, S., Gasparini, F.: EEG-based BCIs on motor imagery paradigm using wearable technologies: A systematic review. Sensors, vol. 23, no. 5, pp. 2798 (2023) doi: 10.3390/s23052798
15. Scikit Learn: RBF SVM parameters (2024) scikit-learn.org/dev/auto_examples/svm/plot_rbf_parameters.html
16. Sha’abani, M. N. A. H., Fuad, N., Jamal, N., Ismail, M. F.: kNN and AVM classification for EEG: A review. In: The 11th Annual Energy Conversion Congress and Exposition, vol. 632, pp. 555–565 (2020) doi: 10.1007/978-981-15-2317-5_47