

Mecanismo de Detección de Carga Cognitiva basado en Machine Learning Aplicado a Conductores

Cognitive Load Detection Mechanism based on Machine Learning Applied to Drivers

Gustavo Morentín Ballesteros¹, Juan Antonio Guerrero-Ibáñez² y Juan Contreras- Castillo³

¹ Facultad de Telemática – Universidad de Colima, Av. Universidad #333, Colonia Las Víboras, Colima, Colima, 28017. México
gmorentin@uocol.mx¹, antonio_guerrero@uocol.mx², juancont@uocol.mx³

Fecha de recepción: 22 de julio de 2022

Fecha de aceptación: 22 de septiembre de 2022

Resumen. Cada año miles de personas mueren en accidentes de tránsito. Generalmente, la causa de estos accidentes se debe a cansancio, somnolencia, estrés, distracciones, entre otras causas. Este proyecto tiene como objetivo contribuir en la prevención de accidentes automovilísticos a través de la detección de estados de ánimo en los conductores. El trabajo propone una arquitectura basada en Machine learning para analizar las ondas cerebrales del conductor y detectar estados emocionales que puedan generar una situación de peligro tanto para el conductor como para el resto de las personas circulando dentro de su zona de desplazamiento. Los resultados obtenidos muestran una exactitud de 95% de precisión en la detección de la carga cognitiva del conductor.

Palabras Clave: Accidentes viales, carga cognitiva, ondas cerebrales, machine learning.

Summary. Most pattern recognition systems use only one feature vector to describe the objects to be recognized. In this paper we suggest using more than one feature vector to improve the classification results. The use of several feature vectors requires a special neural network, a supervised ART2 NN is used [1]. The performance of a supervised or unsupervised ART2 NN depends on the appropriate selection of the vigilance threshold. If the value is near to zero, a lot of clusters will be generated, but if it is greater, then clusters will be generated. A methodology to select this threshold was first proposed in [2]. The advantages to use several feature vectors instead of only one are shown on this work. We show some results in the case of character recognition using one and two feature vectors. We also compare the performance of our proposal with the multilayer perceptron.

Keywords: Road accidents, Cognitive load, Brain waves, Machine learning.

1 Introducción

De acuerdo con un informe de la Organización Mundial de la Salud (OMS) con relación a la situación mundial de la seguridad vial, más de 1.3 millones de personas muere cada año en las carreteras del mundo, además de los millones de personas que resultan lesionadas de gravedad [1]. Además, entre 20 y 50 millones de personas sufren traumatismos, muchos de los cuales provocan alguna discapacidad. Las lesiones ocasionan altas pérdidas económicas para los familiares y para el gobierno. El informe menciona que los costos asociados a las colisiones equivalen aproximadamente a un 3% del PIB. Por esto, la conducción de vehículos se ha convertido en un área de investigación importante ya que su mala ejecución puede tener consecuencias fatales.

Cuando una persona realiza la actividad de conducción necesita un alto nivel de concentración, lo que incrementa la carga cognitiva y puede ocasionar situaciones de riesgo al mínimo descuido [2]. En [3] definen la carga cognitiva como la capacidad de demanda mental que requiere una persona para realizar una tarea específica. Cuando se excede el nivel de esfuerzo mental al realizar una actividad, el conductor puede sufrir deficiencias para procesar la información, disminuyendo su velocidad de respuesta, incrementando la posibilidad de cometer errores. Si hay mucha demanda mental, el conductor podría percibir un nivel de estrés elevado, pero, cuando la demanda es excesivamente baja, el conductor puede percibir fatiga. Cuanto mayor sea la cantidad de demanda mental requerida por el sujeto para realizar una actividad, mayor será la demanda de la carga cognitiva utilizada [4]. Un área donde se está monitoreando continuamente la carga cognitiva de las personas es en los sistemas de interacción Máquina-Sujeto, con el fin de ayudar a optimizar su desempeño y evitar errores en períodos prolongados de exceso de carga mental. Por esta razón, es importante que se realice un monitoreo permanente de la carga cognitiva de las personas que realiza una actividad que demanda altos niveles de atención y concentración con el fin de detectar sobrecarga mental [5].

En este trabajo, se presenta la propuesta de un mecanismo para predicción de estados de bajan y alta carga cognitiva basado en algoritmos de aprendizaje automatizado y mediciones de ondas cerebrales aplicado a conductores de vehículos con el fin de detectar niveles que puedan generar situaciones de riesgo dentro de su entorno de conducción.

2 Estado del Arte

Medir la carga cognitiva en las personas que realizan una actividad específica nos proporciona información sobre el desgaste mental que requiere la persona para realizar una actividad. A mayor dificultad para realizar la tarea, generalmente se produce un decremento en el rendimiento de la persona y el número de tareas completadas por unidad de tiempo, ocasionando mayores tiempos de respuesta y un incremento en el número de tareas mal realizadas.

La carga cognitiva no puede medirse directamente por lo que se han desarrollado herramientas que se basan en la observación del comportamiento de la persona utilizando tres principales enfoques: I) medidas subjetivas, que aplican cuestionarios para evaluar diferentes aspectos y obtener una escala cognitiva, II) medidas de rendimiento que miden la capacidad de la persona para mantener el sistema dentro de unos márgenes definidos, obteniendo una correlación entre el desempeño obtenido y la carga cognitiva requerida para realizar la actividad y III) medidas fisiológicas que realizan un monitoreo interno de la persona en tiempo real, por lo que son las herramientas más útiles para evaluar la carga cognitiva de la persona [6]. Para este último enfoque se utilizan diversas señales fisiológicas tales como electroencefalográficas (EEG), electrocardiograma (ECG), electrooculograma (EOG) y electromiograma (EMG) [7].

En la literatura encontramos que la señal fisiológica EEG es la más utilizada para la detección de niveles de carga emocional en la personas [8]–[10]. El EEG registra la actividad bioeléctrica cerebral de la persona, las cuales son más sensibles a los cambios de estados cognitivos y, por lo tanto, facilitan la detección con mayor precisión alertas de baja o alta carga cognitiva en comparación con otros indicadores fisiológicos.

El principal problema de este tipo de señal fisiológica es que genera mucha información por segundo, que se incrementa de acuerdo con la duración de la medición y el número de canales del sensor, lo que se traduce en un tratamiento complejo y robusto [11], [12]. El reto principal para EEG es encontrar la información adecuada para identificar estados cognitivos. Para solventar este reto se utilizan algoritmos de selección de características (FS) que se enfocan en encontrar un conjunto de características con información o datos relevantes que puedan identificar o describir un evento, permitiendo que el maximizar el rendimiento de los modelos de predicción [13].

En [14], los autores proponen GALoRIS, un método basado en Machine Learning para filtrar la información de ondas electromagnéticas, con el fin de reducir los tiempos de procesamiento para identificar estados de ánimo en personas. En [15] se muestra que la clasificación del EEG basada en la computación suave mediante la extracción y posterior selección de características óptimas puede producir mejores resultados en precisión, sin embargo hace uso de los datos de todas las ondas cerebrales, lo que incrementa su tiempo de procesamiento. En [16] se presenta una red neuronal convolucional recurrente basada en la atención para extraer las señales de EEG y mejorar la precisión del reconocimiento de emociones. En [17], se propone una red capsular efectiva guiada por características de varios niveles para extraer características de las señales de EEG y determinar los estados emocionales. El método alcanza una precisión media del 97,97% y del 94,59% pero presenta una complejidad de red.

Los modelos descritos anteriormente utilizan técnicas que intentan mejorar la precisión mediante el uso de características del conjunto de datos original, obteniendo modelos de predicción o analizando la información de una señal específica para comparar varias características utilizando pequeños conjuntos de datos y descartando la información relevante, sin embargo, el principal problema es la complejidad de procesamiento.

En este trabajo se propone el uso de señales EEG para identificar estados de carga cognitiva en los conductores que pudieran generar situaciones de riesgo dentro de su entorno de desplazamiento.

3 Descripción de la Propuesta

El objetivo de la propuesta es identificar dos niveles de carga, el primero está relacionado con el nivel de concentración y el segundo con el cansancio. Se realizó una investigación para identificar las ondas cerebrales que se relacionan estrechamente con los estados de concentración y cansancio [18]. De acuerdo con [18], las ondas Beta (12-30 Hz) están presentes cuando estamos atentos y envueltos en la resolución de tareas o problemas cotidianos, también durante la toma de decisiones o cuando estamos concentrados. Sin embargo, cuando se tienen valores elevados de Beta indica estrés, lo que puede perjudicar la tarea de conducción. Las ondas Alfa (8-12 Hz) se relacionan con el estado que se adquiere cuando el sistema nervioso se encuentra en reposo, relajado pero despierto y atento, un valor elevado de Alfa indica una desconcentración. Las ondas Theta predominan cuando el individuo procesa información interna, de tal manera que está desconectado del mundo exterior, o durante una meditación profunda, como entre la transición entre vigilia y sueño.

De esta manera las ondas Alfa complementan a las Beta en el proceso de detección de la concentración y las ondas Alfa y Theta (4-8 Hz) están relacionada con el cansancio y el sueño.

Para el proyecto, como elemento auxiliar para la adquisición de datos de las ondas cerebrales, se utilizó un dispositivo en forma de diadema de la marca Epoc modelo Emotiv +. Dicho dispositivo cuenta con 14 canales de medición y sensores que detectan 9 movimientos de cabeza.

La figura 1 muestra la representación del proceso a seguir para el desarrollo de la presente propuesta. La propuesta consistió en 6 etapas, las cuales se describen de forma general a continuación.




Figura 1. Etapas del modelo propuesto.

3.1 Adquisición de datos

Esta etapa consiste en la recolección de los datos de ondas cerebrales de diferentes personas realizando la actividad de conducción de un vehículo durante un periodo de tiempo con el fin de que el conductor se enfrente a diferentes situaciones de conducción durante la ejecución de la actividad.

3.2 Pre-procesamiento de datos

Esta etapa se enfoca en identificar y filtrar los datos relevantes (fig. 2). Se realizó el acomodo de los datos proporcionados por cada uno de los sensores de la diadema utilizada para la lectura de ondas cerebrales. Se filtraron los datos de acuerdo con los estados que se desean identificar, seleccionando solamente las ondas cerebrales (Alfa, Beta y Theta) que son utilizadas para medir esos estados emocionales (concentración y cansancio).




Figura 2. Representación de los datos obtenidos con la diadema Emotiv.

3.3 Creación del dataset

Con los datos filtrados se generó un dataset con la estructura necesaria dentro de un archivo para ser utilizado como fuente de entrada para el proceso de entrenamiento del algoritmo propuesto.

3.4 Diseño del algoritmo

Se desarrolló el mecanismo basado en Machine Learning (ML) para detección de estados cognitivos en personas realizando la tarea de conducción. Como modelo de aprendizaje automatizado se utilizó un algoritmo supervisado para poder generar los datos de salida para el proceso de entrenamiento. El algoritmo utilizado es el K-NN (*K-Nearest-Neighbor*) el cual es un clasificador basado en instancias de tipo supervisado, que hace uso de la proximidad para hacer clasificaciones o predicciones sobre la agrupación de un punto de datos individual (fig. 3). Para la implementación del algoritmo se utilizó el lenguaje de programación Python ya que contiene todas las librerías necesarias para el uso de KNN, se usó la plataforma de Google Colab ya que los datasets se almacenaron en Google Drive.




Figura 3. Representación de funcionamiento general del algoritmo K-NN.

3.5 Entrenamiento y ajustes

Durante esta etapa se procedió al entrenamiento del algoritmo, realizando los ajustes necesarios a los campos usados para obtener un buen nivel de asertividad. El entrenamiento se realizó con los datos recolectados por la medición de datos durante el proceso de conducción y se reforzó con un dataset complementario para incrementar la cantidad de datos utilizados para el entrenamiento [19].

3.6 Pruebas y análisis de resultados

Finalmente, durante esta etapa se procedió a realizar las pruebas directas con datos recopilados del sensor Emotiv. Se analizaron los resultados obtenidos con relación a la identificación de los estados de concentración y cansancio.

4 Pruebas y Resultados

Para la adquisición de datos del modelo se utilizaron 20 conductores que realizaron actividades de conducción por un promedio de 30 minutos, siempre usando la diadema para la adquisición de los datos. Todos los datos fueron almacenados directamente en una computadora. Los datos en bruto adquiridos durante el proceso estaban formados por los valores de las diferentes ondas cerebrales obtenidas por la diadema. Los datos recolectados fueron filtrados, seleccionando únicamente los valores de las señales Alfa, Beta y Theta, creando el dataset que fue almacenado en Google Drive. La fig. 4 muestra los resultados obtenidos en las pruebas realizadas. Una vez teniendo el dataset ya listo para usar se procedió a generar dos columnas nuevas ambas solo tienen 2 valores 1 y 0, el primer campo es para cuando la persona está concentrada y el segundo es para cuando una persona tiene un estado de cansancio.

Se puede observar en la imagen que la puntuación obtenida en f1, la cual es considerada una media armónica de los parámetros de precisión y recall proporciona una puntuación de evaluación del rendimiento fiable. Las pruebas arrojaron una precisión mayor al 75% para el parámetro f1 por lo cual es considerado un modelo aceptable. Los resultados muestran que para detectar la concentración se tuvo una asertividad de 81%, mientras que para el cansancio se obtuvo un valor de 70%. Ambos valores son aceptables y ya proporcionan información que nos permite detectar una situación que podría generar un riesgo dentro del entorno de conducción.

```

[[3488 1423]
 [1624 6607]]
precision    recall  f1-score   support

     0         0.68         0.71         0.70         4911
     1         0.82         0.80         0.81         8231

 accuracy                0.77         13142
 macro avg              0.75         0.76         0.75         13142
 weighted avg          0.77         0.77         0.77         13142

```

Figura 4. Resultados obtenidos en la evaluación del algoritmo.

5 Conclusiones

En este trabajo se presentó un modelo basado en machine learning para detectar estados de ánimo en conductores. Los resultados obtenidos muestran que el algoritmo propuesto pudo analizar la carga cognitiva en los conductores con el fin de detectar cansancio o nivel de concentración al momento de realizar la actividad de conducción. Los resultados mostraron un nivel de asertividad mayor al 75% por lo cual la utilización del modelo para detectar situaciones de riesgo.

El modelo actual tiene poco más de 50,000 resultados por lo cual es posible afinar más el modelo a través de un entrenamiento con mayor cantidad de datos. Como trabajo futuro se incluirán datos de otros signos vitales como el ritmo cardiaco para incrementar la precisión del algoritmo.

Agradecimientos

Queremos agradecer al Consejo Nacional de Ciencia y Tecnología (CONACYT), por el soporte económico para el desarrollo de esta investigación como parte de los estudios de maestría en Tecnologías de Internet de Gustavo Morentín Ballesteros.

Referencias

- [1] Organización Mundial de la Salud, «Traumatismos causados por el tránsito», Organización Mundial de la Salud, 2022. [En línea]. Disponible en: <https://www.who.int/es/news-room/fact-sheets/detail/road-traffic-injuries>
- [2] L. Yan, Z. Huang, Y. Zhang, L. Zhang, D. Zhu, y B. Ran, «Driving risk status prediction using Bayesian networks and logistic regression», *IET Intell. Transp. Syst.*, vol. 11, n.º 7, pp. 431-439, 2017, doi: <https://doi.org/10.1049/iet-its.2016.0207>.
- [3] S. Wang, J. Gwizdka, y W. A. Chaovalitwongse, «Using Wireless EEG Signals to Assess Memory Workload in the \$n\$-Back Task», *IEEE Trans. Hum.-Mach. Syst.*, vol. 46, n.º 3, pp. 424-435, 2016, doi: 10.1109/THMS.2015.2476818.
- [4] D. Rozado y A. Dünser, «Combining EEG with Pupillometry to Improve Cognitive Workload Detection», *Computer*, vol. 48, n.º 10, pp. 18-25, 2015, doi: 10.1109/MC.2015.314.
- [5] P. Zarjam, J. Epps, y N. H. Lovell, «Beyond Subjective Self-Rating: EEG Signal Classification of Cognitive Workload», *IEEE Trans. Auton. Ment. Dev.*, vol. 7, n.º 4, pp. 301-310, 2015, doi: 10.1109/TAMD.2015.2441960.
- [6] J. Albetosa, E. Galy, y C. Berthelon, «Mental workload and driving», *Front. Psychol.*, vol. 5, p. 1344, dic. 2014, doi: 10.3389/fpsyg.2014.01344.
- [7] J. A. Blanco *et al.*, «Quantifying Cognitive Workload in Simulated Flight Using Passive, Dry EEG Measurements», *IEEE Trans. Cogn. Dev. Syst.*, vol. 10, n.º 2, pp. 373-383, 2018, doi: 10.1109/TCDS.2016.2628702.
- [8] C. Mühl, C. Jeunet, y F. Lotte, «EEG-based Workload Estimation Across Affective Contexts», *Front. Neurosci.*, vol. 8, p. 114, jun. 2014, doi: 10.3389/fnins.2014.00114.

- [9] B. Y. Marquez Lobato y A. Alanis Garza, «Classification algorithm for measuring human emotion: “I like it” and “I do not like” in Neuromarketing», *IEEE Lat. Am. Trans.*, vol. 15, n.º 11, pp. 2177-2184, 2017, doi: 10.1109/TLA.2017.8070424.
- [10] L. Cao, J. Li, Y. Xu, H. Zhu, y C. Jiang, «A Hybrid Vigilance Monitoring Study for Mental Fatigue and Its Neural Activities», *Cogn. Comput.*, vol. 8, n.º 2, pp. 228-236, abr. 2016, doi: 10.1007/s12559-015-9351-y.
- [11] M. Z. Baig, N. Aslam, y H. P. H. Shum, «Filtering techniques for channel selection in motor imagery EEG applications: a survey», *Artif. Intell. Rev.*, vol. 53, n.º 2, pp. 1207-1232, feb. 2020, doi: 10.1007/s10462-019-09694-8.
- [12] L. Wang *et al.*, «Automatic Epileptic Seizure Detection in EEG Signals Using Multi-Domain Feature Extraction and Nonlinear Analysis», *Entropy*, vol. 19, n.º 6, 2017, doi: 10.3390/e19060222.
- [13] B. Nakisa, M. N. Rastgoo, D. Tjondronegoro, y V. Chandran, «Evolutionary computation algorithms for feature selection of EEG-based emotion recognition using mobile sensors», *Expert Syst. Appl.*, vol. 93, pp. 143-155, 2018, doi: <https://doi.org/10.1016/j.eswa.2017.09.062>.
- [14] P. Becerra-Sánchez, A. Reyes-Munoz, y A. Guerrero-Ibañez, «Feature Selection Model based on EEG Signals for Assessing the Cognitive Workload in Drivers», *Sensors*, vol. 20, n.º 20, 2020, doi: 10.3390/s20205881.
- [15] M. H. Bhatti *et al.*, «Soft Computing-Based EEG Classification by Optimal Feature Selection and Neural Networks», *IEEE Trans. Ind. Inform.*, vol. 15, n.º 10, pp. 5747-5754, 2019, doi: 10.1109/TII.2019.2925624.
- [16] W. Tao *et al.*, «EEG-based Emotion Recognition via Channel-wise Attention and Self Attention», *IEEE Trans. Affect. Comput.*, vol. PP, sep. 2020, doi: 10.1109/TAFFC.2020.3025777.
- [17] Y. Liu *et al.*, «Multi-channel EEG-based emotion recognition via a multi-level features guided capsule network», *Comput. Biol. Med.*, vol. 123, p. 103927, ago. 2020, doi: 10.1016/j.compbiomed.2020.103927.
- [18] Neurofeedback, «¿Qué son las ondas Cerebrales?», 2019. [En línea]. Disponible en: <https://www.neurofeedback.cat/que-son-las-ondas-cerebrales/>
- [19] Kaggle, «Database for Emotion Recognition System - GAMEEMO», 2021. [En línea]. Disponible en: <https://www.kaggle.com/datasets/sigfest/database-for-emotion-recognition-system-gameemo>