

Detection of Emergency Braking Intention Using Driver's Electroencephalographic Signals

L. Hernández, E. Martínez, and J. Antelis

Abstract—This work investigates the recognition of the intention to perform emergency braking from driver's electroencephalographic (EEG) signals. To do so, brain signals and vehicle data were recorded in a simulated driving environment while participants had to drive and to avoid potential collisions by performing emergency braking. To resemble realistic conditions, emergency braking were performed during the presence and absence of stress, workload and fatigue. Brain signals were used to study the classification between emergency braking intention and normal driving. The results showed significant classification accuracies around 80% using EEG signals from the left hemisphere. On the basis of these results, this work shows the feasibility of incorporating recognizable driver's brain signals into advanced driver-assistance systems to carry out early detection of emergency braking situations.

Index Terms—Driving, Braking, Intention, Electroencephalogram, Detection, Stress, Workload, Fatigue.

I. INTRODUCCIÓN

ACTUALMENTE en el mundo, 1.3 millones de personas mueren al año debido a accidentes de tránsito [1]. Adicionalmente, alrededor de 50 millones de personas sufren alguna discapacidad provocada por este tipo de accidentes. Para el 2020 se estima que los accidentes de tránsito serán la quinta causa de muerte, alcanzando los 2.4 millones de personas fallecidas por año [2]. Entre las causas de la alta mortalidad y accidentalidad vehicular se encuentran los errores del conductor [3], los cuales son desencadenados por factores como fatiga o realización de otras actividades durante la conducción [4]–[7]. Para reducir esta problemática, los nuevos modelos de vehículos comienzan a incorporar sistemas avanzados de asistencia al conductor (SAAC) [8]. Estos sistemas utilizan diversos sensores (sonar, láser, entre otros) para registrar y analizar información del ambiente que ayuda al conductor a reconocer y reaccionar ante situaciones de tráfico potencialmente peligrosas [9]. Sin embargo, los SAAC no utilizan información del conductor, esto implica que no responden ante situaciones peligrosas originadas por factores humanos [10]. Debido a esto, una tendencia reciente en los SAAC es incorporar información obtenida directamente del conductor y su comportamiento durante el manejo [11], [12]. Por ejemplo, se ha propuesto el registro de imágenes o de la actividad bioeléctrica para detectar distracciones o somnolencia [13].

Una situación potencialmente crítica durante la conducción es el *frenado de emergencia*. Ante esto, los sistemas de frenado automático de emergencia (FAE) detectan un choque

inminente con otro vehículo a tiempo para evitar o mitigar el choque. Para esto, los FAE detectan obstáculos imprevistos a través de los sensores que registran información del exterior y validan la situación de frenado de emergencia con la activación súbita del pedal de freno. Como resultado se genera una acción de frenado más pronta que la realizada manualmente por el conductor [14]. Notar que el accionamiento del pedal del freno por parte del conductor es el resultado final de una serie de procesos neuronales que inician con la interpretación de la situación y culminan con la activación muscular para mover el pie y accionar el pedal [15], [16]. Por lo tanto, se puede estudiar actividad cerebral del conductor que antecede al momento en que se acciona el pedal del freno para detectar la intención de frenado de emergencia. Esto puede ayudar a disminuir el tiempo de reacción de frenado.

Investigaciones recientes han abordado la detección de intención de frenado usando actividad cerebral. Inicialmente se propuso una metodología para detectar la intención de frenado en un ambiente de conducción simulada [17] y real [18]. Estos trabajos demostraron la viabilidad de usar señales eléctricas cerebrales del conductor para anticipar a la acción de frenado. Posteriormente se estudió la actividad cerebral en diversas situaciones de frenado (suaves, bruscos y emergencia) en un entorno de conducción simulado [19] y los resultados mostraron correlaciones neuronales que pueden ser utilizadas para discriminar entre los diversos tipos de intención de frenado. Estos trabajos se realizaron en condiciones controladas en las cuales los participantes no experimentan situaciones que puedan afectar o retrasar la realización de frenados. En un contexto real, sin embargo, los conductores están expuestos a factores como estrés, carga de trabajo y fatiga, los cuales alteran la toma de decisiones y disminuyen la atención [20]–[22], lo que a su vez aumenta los tiempos de reacción de frenado [23], [24]. Por lo tanto, es importante estudiar la actividad cerebral del conductor durante frenados de emergencia cuando su nivel de atención puede ser afectado por estos factores.

En este trabajo se propone la detección de intención de frenado de emergencia utilizando señales electroencefalográficas (EEG) del conductor registradas en situaciones de conducción con presencia o ausencia de estrés, carga de trabajo y fatiga. Para esto, se realizó un experimento en el cual varios voluntarios manejan un vehículo en un ambiente virtual a la vez que realizan frenados de emergencia para evitar chocar contra otro vehículo. Durante la ejecución del experimento se registraron señales vehiculares y cerebrales, las cuales se utilizaron para estudiar la detección de intención de frenado de emergencia. Los resultados mostraron que es posible usar señales EEG previas al momento en que se acciona el pedal del freno y un algoritmo de clasificación para reconocer la intención de

frenado de emergencia realizada en situaciones de conducción que incluyen estrés, carga de trabajo y fatiga. Se obtuvo un rendimiento de $\sim 80\%$ usando electrodos ubicados sobre la corteza motora del hemisferio izquierdo del cerebro. Este estudio muestra la posibilidad de incorporar en los sistemas FAE información proveniente de las señales cerebrales del conductor para la detección anticipada de potenciales situaciones que requieren frenado de emergencia. Esto podría ser útil como información que complementa a los sistemas FAE actuales a predecir y validar una situación potencial de frenado de emergencia, reduciendo la accidentalidad y mortalidad asociada al tránsito vehicular.

II. MATERIALES Y MÉTODOS

A. Participantes

Siete personas diestras (23.9 ± 5.0 años de edad) participaron voluntariamente en este estudio. Todos los participantes aprobaron los siguientes criterios de inclusión: (i) saber manejar un vehículo con embrague manual o automático, (ii) contar con licencia vigente para conducir automóvil, (iii) no tener historial de enfermedades neurológicas y/o psiquiátricas. El experimento se llevó a cabo de acuerdo con la declaración de Helsinki y se entregó consentimiento informado el cual fue aceptado y firmado por cada uno de los participantes.

B. Plataforma y Ambiente de Conducción Simulada

La plataforma de conducción consistió de un juego de pedales, volante y palanca de cambios para simulador de conducción (G27 Logitech Racing Wheel), una pantalla de 19 pulgadas para visualización del ambiente de conducción y un computador para administrar y gestionar la ejecución del experimento y la adquisición de señales (Figura 1). El ambiente de conducción se desarrolló utilizando el software de código abierto TORCS (The Open Racing Car Simulator) [25]. Este ambiente consistió de una pista tipo óvalo de dos carriles. Además, contenía un *vehículo guía* manejado de forma autónoma que se visualizaba adelante del vehículo controlado por el participante. El *vehículo del participante* se visualizó en perspectiva de primera persona, con embrague automático y controlado por el volante y los pedales.

A partir de esta plataforma y ambiente de conducción se adquirieron dos señales a una frecuencia de muestreo de 50 Hz: (i) estado de las luces de frenado traseras del vehículo guía o LVG (señal binaria en donde 0 corresponde a luces apagadas y 1 corresponde a luces encendidas), (ii) el nivel de activación del pedal de freno del vehículo controlado por el participante o FVP (señal en el rango de 0 a 1 con resolución de 0.001 en donde 0 corresponde a pedal sin activar y 1 corresponde a pedal completamente activado).

C. Señales Cerebrales

La electroencefalografía (EEG) es una técnica de registro no invasivo de la actividad eléctrica del cerebro [26]. En estas señales se pueden encontrar información relevante relacionada a diversas actividades cerebrales (por ejemplo, control motor, procesamiento visual y auditivo), la cual puede ser utilizada

para generar un canal de comunicación no-natural entre el cerebro y un ambiente externo [27]. Esta información puede ser extraída a través de diversas técnicas de procesamiento de señales en el dominio del tiempo y de la frecuencia [28]. Características detalladas acerca de la técnica de EEG son abordados en [29].

En este trabajo se registró las señales EEG de siete electrodos (F3, F4, C3, C4, Cz, P3, P4) acorde con el sistema internacional 10/20. La frecuencia de muestreo fue de 500 Hz usando un dispositivo BIORADIO PG (Great Lakes NeuroTech, USA). El electrodo de tierra y de referencia se ubicó por encima de la apófisis mastoides de la parte derecha del cráneo. Se utilizaron electrodos de copa de oro y se aplicó pasta conductora para asegurar una impedancia menor a los 5 K Ω .

D. Descripción del Experimento

El experimento consistió en conducir el *vehículo del participante* siguiendo a una distancia constante y cercana al *vehículo guía* mostrado en la pantalla. El vehículo guía se desplazaba a una velocidad constante de 100 kmh $^{-1}$, tiempo después disminuía súbitamente la velocidad hasta alcanzar 60 kmh $^{-1}$. Esta acción fue acompañada del encendido de las luces de frenado traseras, lo que produce un *estímulo* visual que indica al participante realizar la *respuesta* de oprimir el pedal del freno para evitar una colisión. Esta situación de *frenado de emergencia* es realizada en repetidas ocasiones en intervalos de ocurrencia variable para que los participantes no generen una respuesta anticipada de frenado.

Durante la realización de este experimento, los participantes fueron expuestos a diferentes combinaciones de situaciones de estrés, carga de trabajo y fatiga. Para el estrés se generó el sonido de una sirena de ambulancia a una intensidad de 90 dB lo cual se encuentra en el rango de molestia para el oído humano (70-100 dB) [30]. Esta señal externa, repetitiva y de alta intensidad genera perturbación y ansiedad a conductores lo que conlleva al estrés [24]. Para la carga de trabajo se pidió realizar una tarea de atención simultánea (TAS) adicional a la tarea de conducción [31], [32]. La TAS consistió en tocar la palanca de cambios con la mano derecha (acción sin efecto en la conducción del vehículo) como respuesta a la presentación de una imagen con el símbolo "X" mostrada aleatoriamente en una pantalla secundaria ubicada en frente del participante pero fuera del campo de visión hacia la pantalla principal. Finalmente, para la fatiga se consideró el agotamiento físico y mental asociados a la realización de actividades de la vida diaria durante el transcurso del día. Por lo tanto, se ejecutaron experimentos durante el mismo día en la mañana (entre las 09:00 a 12:00 horas, en donde se asume que el participante se encuentra relajado y descansado después del sueño nocturno reparador) y en la tarde (entre las 16:00 y 19:00 horas, en donde se asume que el participante se encuentra cansado) [33]–[35].

El experimento se realizó en cuatro sesiones de conducción aproximadamente 30 minutos. Se realizaron dos sesiones en la mañana y dos sesiones en la tarde. Como resultado, por cada participante se registraron 480 frenados de emergencia en los

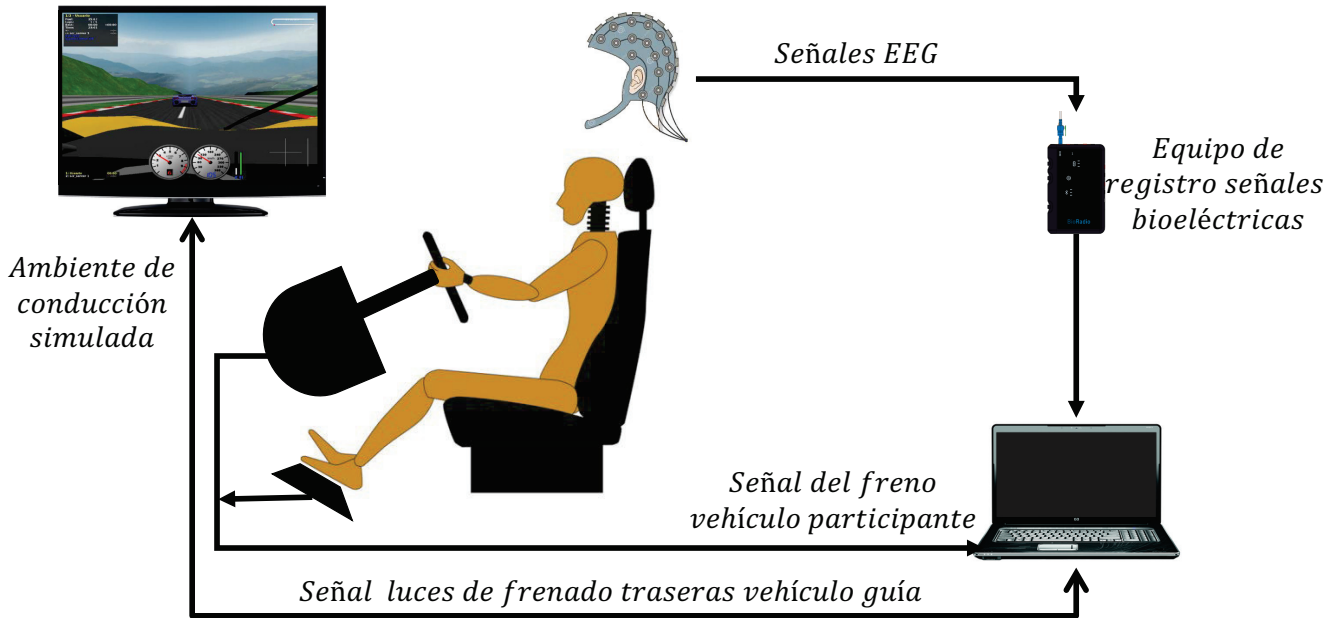


Fig. 1. Plataforma de conducción simulada. Esta plataforma consistió de un juego de pedales, volante y palanca de cambios para simulador de conducción, una pantalla de 19 pulgadas para visualización del ambiente de conducción y un computador para administrar y gestionar la ejecución del experimento.

cuales los participantes estuvieron sometidos a cualquiera de las ocho posibles combinaciones con presencia o ausencia de estrés, carga de trabajo y fatiga.

E. Pre-procesamiento

Las señales vehiculares (LVG y FVP) y cerebrales (EEG) fueron adquiridas de diferentes entornos de software a través de un mismo computador. Por lo tanto, los registros de las diferentes señales son obtenidas utilizando un reloj común. Esto permitió poder sincronizar las diferentes señales para iniciar y terminar en los mismos instantes de tiempo. Posteriormente, a las señales EEG se les aplicó un filtro pasa-bajo tipo Chebychev de orden 2 con frecuencia de corte 45 Hz y un filtro de referencia común. Después de esto, las señales LVG y FVP se sobremuestraron mientras que las señales EEG se submuestraron, en ambos casos a una frecuencia de 250 Hz. Posteriormente, se identificaron los instantes de tiempo en que se activan las luces de frenado traseras del vehículo guía o el cambio de 0 a 1 de la señal LVG (definido como *estímulo*). Los estímulos se usaron como referencia para recortar cada sesión en bloques de datos consecutivos que inician 1500 ms antes de un estímulo y terminan 1500 ms antes del siguiente estímulo. En cada bloque de datos se identificó el instante de tiempo de la primera activación del pedal de freno del vehículo del participante posterior a la aparición del estímulo visual proveniente del vehículo guía (definido como *respuesta*).

Los instantes de tiempo de la respuesta de cada bloque de datos se emplearon para recortar las señales en segmentos de 1500 ms. Como resultado se conformaron dos conjuntos de datos: (i) ensayos con intención de frenado de emergencia: segmentos en el intervalo de $[-1500, 0]$ ms en donde el tiempo de referencia $t = 0$ corresponde a la respuesta o activación del pedal de freno por parte del participante (Figura 2a). (ii)

ensayos sin frenado: segmentos en condiciones normales de conducción en los que no hay frenado y que están a más de 2000 ms aparte de la respuesta (Figura 2b).

F. Detección de la Intención de Frenado de Emergencia

La detección de intención de frenado de emergencia se estudió usando características de las señales EEG en el dominio del tiempo y un clasificador basado en análisis lineal discriminante (LDA).

1) *Extracción y selección de características*: Las señales EEG en el dominio del tiempo se usaron como características para reconocer entre intención de frenado y no frenado. La señal EEG de cada electrodo (1500 ms de duración) se dividió en 10 intervalos (sin traslape) de 150 ms y en cada intervalo se calculó el promedio. Como resultado, para cada electrodo el vector de características es $\mathbf{x} = [x_1, x_1, \dots, x_{10}]^T$. A su vez, los valores de todos los electrodos se concatenaron por lo que el vector de características es $\mathbf{x} = [x_1, x_1, \dots, x_{70}]^T$. Estas características se calcularon en cada muestra del conjunto de ensayos con intención de frenado y del conjunto de ensayos sin frenado y fueron etiquetadas como *frenado* ó 1 y *no frenado* ó 0, respectivamente. Para obtener un vector de características de menor dimensión pero con alto poder discriminativo se aplicó el método de coeficiente de correlación al cuadrado (R^2) [36]. Dado el conjunto de N ejemplos $\{(\mathbf{x}_i, y_i), i = 1, \dots, N\}$, donde $\mathbf{x}_i \in \mathbb{R}^p$ y $y_i = \{1, 0\}$, la selección de características consistió en calcular independientemente el valor de R^2 entre todos los valores de cada característica y las correspondiente clases y posteriormente escoger las p características que presentan el mayor valor de correlación [26]. Este método de selección solo se aplicó si el vector de características estaba conformado por los valores obtenidos de todos los electrodos, y se escogieron $p = 10$

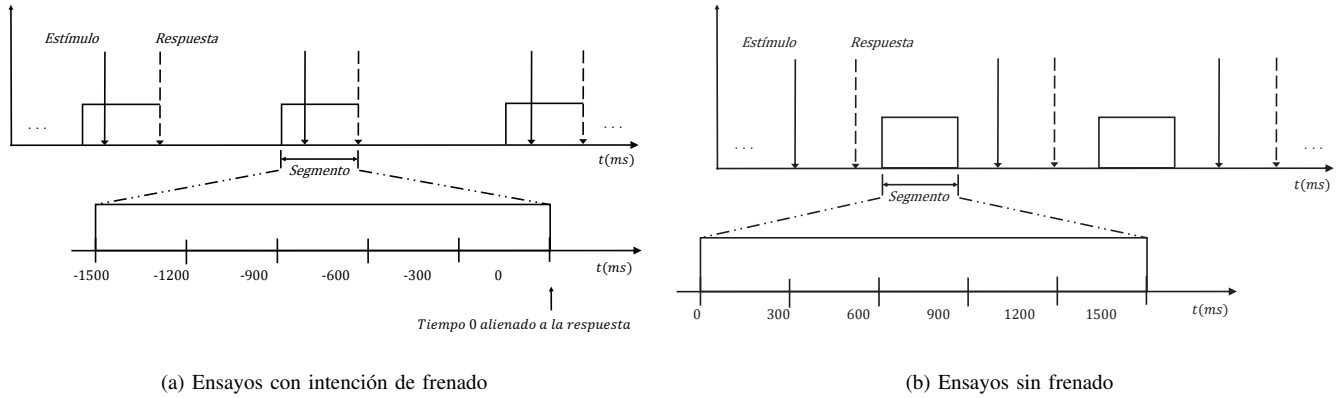


Fig. 2. Ilustración del proceso de extracción de los dos conjuntos de datos: (a) Ensayos con intención de frenado: segmentos de 1500 ms que preceden el accionamiento del pedal del freno, (b) Ensayos sin frenado: segmentos de 1500 ms en los que no hay un frenado de emergencia.

características para coincidir con el número de características de cada electrodo.

2) *Clasificador*: Para discriminar entre intención frenado y no frenado se usó LDA como algoritmo de clasificación [37]. Este algoritmo es muy sencillo de implementar y ofrece buenos resultados de clasificación en aplicaciones con señales EEG [38]–[40]. El objetivo de LDA es calcular un hiperplano de separación $\mathbf{w}^T \cdot \mathbf{x} = 0$, donde $\mathbf{x} \in \mathbb{R}^{p \times 1}$ es el vector de características y $\mathbf{w} \in \mathbb{R}^{p \times 1}$ es un vector de pesos que debe ser calculado. Dado el conjunto de N ejemplos $\{(\mathbf{x}_i, y_i), i = 1, \dots, N\}$ (o conjunto de entrenamiento), el vector de pesos se calcula a través del siguiente problema de optimización [41]:

$$\mathbf{w} = \underset{\mathbf{w}}{\operatorname{arg\,max}} = \frac{\mathbf{w}^T \mathbf{S}_B \mathbf{w}}{\mathbf{w}^T \mathbf{S}_W \mathbf{w}} \quad (1)$$

Donde \mathbf{S}_B es la matriz de covarianza entre clases y \mathbf{S}_W es la matriz de covarianza dentro de la clase [41]. Finalmente, la función que estima la clase para un nuevo vector de características está dada por:

$$\hat{y} = \operatorname{signo}(\mathbf{w}^T \mathbf{x}) \quad (2)$$

Donde $\hat{y} = \{1, 0\}$ es la clase estimada, la cual corresponde a la condición de *frenado* o *no frenado*, respectivamente.

3) *Procedimiento de evaluación*: La clasificación entre frenado y no frenado se evaluó independientemente para cada participante en ocho casos diferentes: usando cada electrodo y usando todos los electrodos (en los ocho casos la dimensión del vector de características es $p = 10$).

Para cada participante y caso, se evaluó el rendimiento de la clasificación mediante la técnica de validación cruzada con diez particiones. Para esto, el conjunto total de datos se dividió en diez partes. De este forma, el entrenamiento del clasificador se realiza con nueve de estas partes (subconjunto de entrenamiento que contiene el 90% de los datos) mientras que el rendimiento de la clasificación se mide con la parte restante (subconjunto de prueba que contiene el 10% de los datos). Este procedimiento se realiza diez veces hasta usar las diez parejas de subconjuntos de entrenamiento y prueba las cuales son mutuamente excluyentes.

Para medir el rendimiento se calculó la precisión de la clasificación o ACC , definida como el porcentaje de ensayos clasificados correctamente. Esta métrica se calculó en cada validación cruzada. Por lo tanto, por cada participante y caso se obtuvo una distribución de ACC y se calculó el promedio y la desviación estándar. Finalmente, el nivel de azar significativo de la precisión de la clasificación o ACC_{sig} se calculó con la distribución binomial acumulativa [42] usando el número de clases N_{clases} , el número de ensayos disponibles N y un nivel de confianza α .

III. RESULTADOS

Cada uno de los bloques de datos se sometió a inspección visual y aquellos con señales vehiculares incongruentes (sin activación del freno del vehículo del participante posterior a la aparición del estímulo) o señales EEG ruidosas (contaminadas con actividad muscular o electrooculográfica) fueron descartados y no usados en los análisis subsecuentes. Como resultado, el promedio del número de situaciones con frenado de emergencia entre todos los participantes fue de 428 ± 56 (mínimo de 300 y máximo de 474). De cada uno de estos bloques se extrajeron los ensayos con intención de frenado junto con los ensayos sin frenado. El nivel de azar significativo de la precisión de la clasificación o ACC_{sig} se calculó usando el número de clases $N_{clases} = 2$, el número de ensayos $N = 600$ (numero de ensayos mínimo entre todos los participantes) y un nivel de confianza de $\alpha = 0.05$. En consecuencia, el nivel de azar significativo fue $ACC_{sig} = 53.6\%$.

En la figura 3a-g se presentan las distribuciones de ACC de cada participante en cada uno de los casos de clasificación. La línea horizontal roja punteada de cada gráfica representa el valor de ACC_{sig} . En primer lugar se consideran los casos de clasificación donde se usa cada electrodo independientemente. Para el electrodo Cz la mediana de la distribución de ACC es mayor y significativamente diferente a ACC_{sig} ($p < 0.05$, prueba de rango con signo de Wilcoxon) en todos los participantes. En los electrodos C3, P3, F3 la mediana de la distribución de ACC es mayor y significativamente diferente a ACC_{sig} ($p < 0.05$, prueba de rango con signo de Wilcoxon) en todos los participantes excepto en el 2

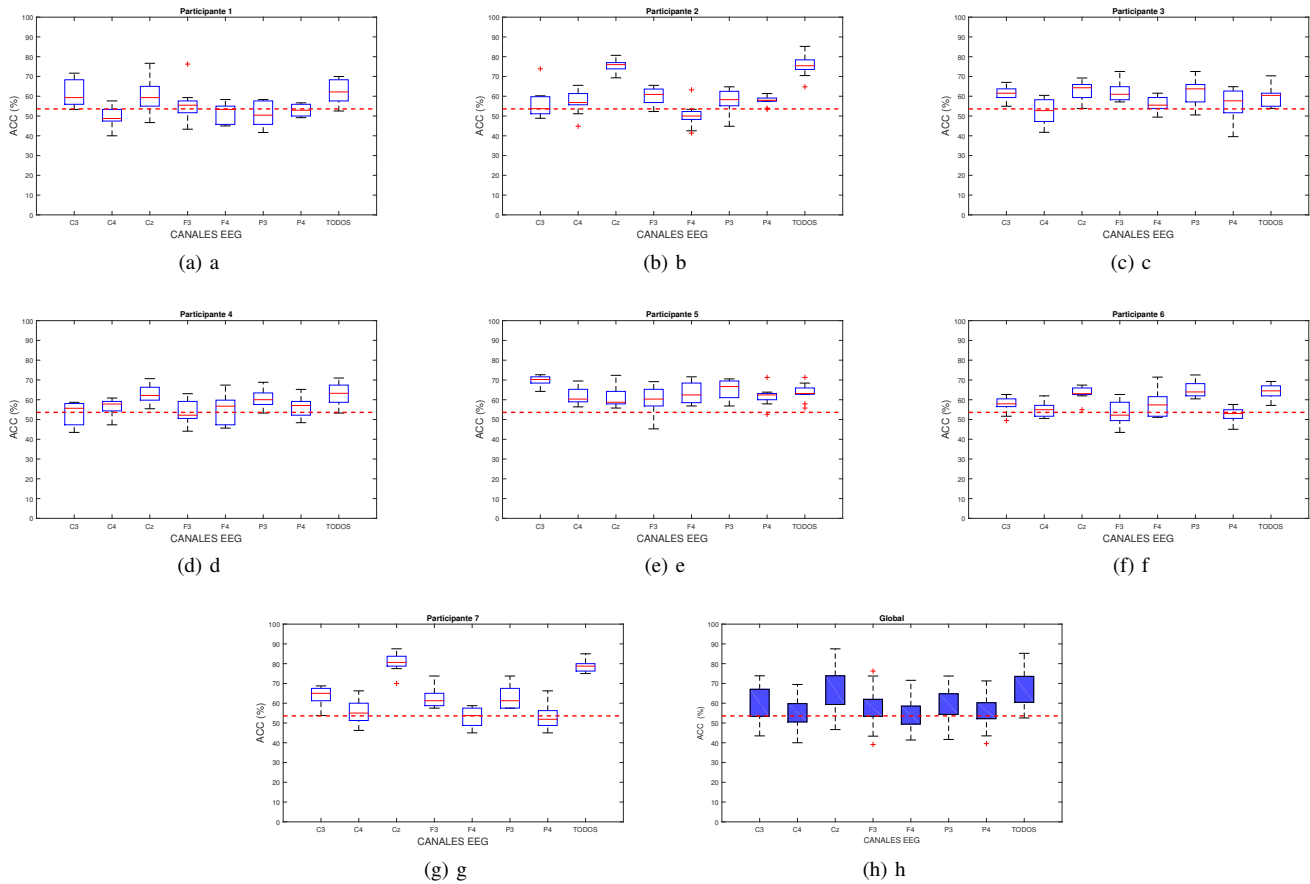


Fig. 3. Distribuciones de ACC de cada participante (a-g) y para todos los participantes (h) para cada caso de clasificación (cada uno de los siete electrodos independientemente y todos los electrodos). La línea horizontal roja punteada de cada gráfica representa el nivel significativo de azar o ACC_{sig} .

y 4, el 1, y el 1, 4 y 6, respectivamente. Finalmente, en los electrodos C4, F4 y P4 la mediana de la distribución de ACC es mayor y significativamente diferente a ACC_{sig} ($p < 0.05$, prueba de rango con signo de Wilcoxon) en tan solo dos de los participantes (el 5 y 7 para C4; el 5 y 6 para F4; el 2 y 5 para P4). Notar que los electrodos Cz, C3, P3 y F3 presentan el mejor rendimiento de clasificación en la mayoría de los participantes. Esto es interesante porque dichos electrodos están ubicados sobre la corteza motora del hemisferio izquierdo la cual es contralateral a la pierna derecha que se mueve para realizar la acción de frenado. Considerando el caso de clasificación en donde se usan todos los electrodos, se observa que ACC es significativamente diferente ($p < 0.05$, prueba de rango con signo de Wilcoxon) y mayor a ACC_{sig} en todos los participantes.

Estos resultados se resumen en la Tabla I donde se muestran la media y la desviación estandar de ACC de cada participante en cada caso de clasificación. Se observa que la media de ACC está por encima del nivel de azar en la mayoría de los participantes para los casos de los electrodos C3, F3, P3, Cz y para el caso de todos los electrodos. El mejor caso de clasificación es el del electrodo Cz en los participantes 2 y 7, en donde la media de ACC es $75.80 \pm 4.01\%$ y $81.25 \pm 4.12\%$, respectivamente. En el caso de clasificación de todos los electrodos, la mayor precisión se obtuvo también

en los participantes 2 y 7 con ACC de $74.67 \pm 4.97\%$ y $78.50 \pm 4.03\%$, respectivamente. Es importante resaltar que en ninguno de los participantes los resultados en este último caso de clasificación son mayores al del caso del electrodo con mayor ACC . Por ejemplo, en el participante 7 el ACC para el caso de todos los electrodos es $78.50 \pm 4.03\%$ mientras que para el caso del electrodo Cz es $81.25 \pm 4.12\%$. Esto sugiere que usar todos los electrodos no mejora la precisión de la clasificación. En general, estos resultados muestran que se pueden usar señales cerebrales para discriminar entre intención frenado y no frenado, y que los mejores rendimientos se obtienen usando información cerebral del hemisferio izquierdo.

En la figura 3h se presentan las distribuciones de ACC de todos los participantes en cada uno de los casos de clasificación (Global). Igualmente, la línea horizontal roja punteada representa el valor de ACC_{sig} . Se observa, que la distribución de ACC es significativamente diferente ($p < 0.05$, prueba de rango con signo de Wilcoxon) y mayor que ACC_{sig} en los casos de clasificación en que se usa cada electrodo localizado en el hemisferio izquierdo (C3, F3 y P3), el electrodo localizado en la línea media (Cz) y todos los electrodos. No hay diferencias significativas ($p > 0.05$, prueba de rango con signo de Wilcoxon) entre la mediana de la distribución de ACC y ACC_{sig} en los casos de clasificación en que se usan

TABLA I
 MEDIA Y DESVIACIÓN ESTÁNDAR DE ACC DE CADA PARTICIPANTE EN CADA CASO DE CLASIFICACIÓN. LAS CANTIDADES EN NEGRITA CORRESPONDEN A LOS VALORES DE ACC CUYA DISTRIBUCIÓN FUE SIGNIFICATIVAMENTE DIFERENTE Y MAYOR A ACC_{sig} .

Participante	Casos de clasificación							
	C3	C4	CZ	F3	F4	P3	P4	TODOS
1	62.91 ± 6.00	53.37±6.84	58.06±4.96	55.18±7.52	50.68±6.21	51.85±5.33	52.03±4.96	62.58±6.40
2	56.62 ± 5.01	57.77±2.96	75.80±4.01	61.52±6.77	53.77±4.16	57.09±4.55	58.34±3.99	74.67±4.97
3	60.33 ± 5.57	51.75±4.36	62.42±6.98	62.64±5.36	56.04±4.78	60.77±4.27	55.82±3.80	61.76±4.42
4	54.23 ± 6.33	55.95±3.87	62.55±4.03	55.42±4.14	56.82±6.32	60.71±3.27	55.64±5.09	62.56±3.94
5	70.19 ± 2.81	62.05±7.14	61.74±5.28	60.89±3.87	63.33±3.15	64.80±2.08	62.69±4.19	64.16±3.37
6	55.13 ± 4.95	53.83±5.84	63.69±5.79	52.41±4.07	58.53±5.30	63.47±5.95	52.52±3.48	63.68±3.31
7	63.75 ± 2.76	54.75±1.42	81.25±4.12	61.13±4.54	50.12±5.88	64.50±6.04	55.50±4.50	78.50±4.03
Global	60.53±5.00	55.46±5.17	66.65±5.02	58.24±5.98	55.14±5.63	60.63±5.46	55.70±4.75	66.81±4.81

los electrodos C4 y F4, los cuales están localizados en el hemisferio derecho del cerebro. Estos resultados confirman que es posible discriminar entre intención de frenado y no frenado y que los mejores rendimientos se obtienen usando señales cerebrales del hemisferio izquierdo.

IV. DISCUSIÓN Y CONCLUSIONES

En este trabajo se estudia la detección de intención frenado de emergencia usando señales cerebrales obtenidas con la técnica del electroencefalograma. Para esto, se diseñó un experimento en el cual varios participantes conducían un vehículo en un ambiente virtual en donde se requería realizar frenados de emergencia. Al mismo tiempo, se registraron señales cerebrales (EEG) del conductor y señales vehiculares (LVG y FVP) del ambiente virtual de conducción. Durante el experimento, los participantes fueron expuestos a combinaciones experimentales de estrés, carga de trabajo y fatiga. Esto se realizó asumiendo que la presencia de estas situaciones representa un acercamiento a las condiciones de conducción real que pueden tener un efecto temporal en la acción de frenado de emergencia. Este experimento fue realizado por 7 participantes.

Para la detección de intención de frenado de emergencia se utilizaron características de las señales EEG en el dominio del tiempo y un clasificador basado en análisis lineal discriminante (LDA). La clasificación entre intención de frenado y no frenado se evaluó independientemente para cada participante en ocho casos diferentes: usando cada electrodo y usando todos los electrodos. En general, en todos los participantes se presentaron al menos 3 casos en los que el valor significativo de azar fue superado. Siendo el participante 5 quien superó el valor significativo en todos los casos de clasificación alcanzando resultados aproximados al 70%. Por otra parte, el participante 1 mostró los resultados con menos casos de clasificación superando el umbral significativo (solo 4 casos de clasificación). Los participantes 2, 5 y 7 presentan al menos un caso de clasificación con ACC con medianas mayores al 70%, que corresponden a valores de los electrodos C3 y/o Cz, en caso contrario solo en el sujeto 3 se presentaron medianas por debajo del 50% (electrodo C4). Se resalta que la media de ACC está por encima del nivel de azar en la mayoría de los participantes para los casos de los electrodos C3, F3, P3 y Cz. Siendo el electrodo Cz el que mejor caso

de clasificación obtuvo. En el caso de clasificación que usa todos los electrodos la mediana de ACC superó el umbral de significativo de azar en todos los participantes. Sin embargo, es resaltable el hecho que en cada uno de los participantes este resultado no fue mayor que en el caso de clasificación usando un electrodo con mayor ACC . Por lo tanto, se infiere que la suma de la información de los electrodos no proporciona mayor rendimiento de clasificación.

Adicionalmente, se observa en la Tabla I los valores medios de los resultados de los 7 participantes en los 8 casos de clasificación (Global). Los valores medios de todos los casos superaron el valor significativo de azar, siendo el caso del electrodo Cz el que presentó mayor promedio de clasificación (66.56% ± 5.02%). El caso contrario fue el caso del electrodo F4 con (54.99% ± 5.25%) el cual presentó el menor porcentaje de clasificación. No obstante este valor se encuentra por encima del valor significativo de azar (53.6%). En estos resultados se comprueba que las características extraídas de la información obtenida por los electrodos Cz, C3 y P3 muestran los mejores rendimientos de clasificación para cualquiera de los sujetos reportados.

En términos generales, los mejores resultados de clasificación ocurren en los electrodos que están localizados en el hemisferio izquierdo (C3, F3 y P3) y en la línea media de la cabeza (Cz). Por lo tanto, estos electrodos se muestran como los sensores base para realizar la detección de intención de frenado. Esto es interesante porque para una aplicación real sería posible disminuir la cantidad de electrodos necesarios para el desarrollo de una aplicación a nivel comercial. Estos resultados muestran que es posible usar señales cerebrales para reconocer entre no frenado e intención de frenado de emergencia con tasas de precisión de alrededor del 80% y significativamente superiores al nivel de azar. Notar que en investigaciones previas se ha reportado tasas de clasificación del 80, 70 y 70% [17]–[19]. Los resultados reportados en este artículo están en el mismo rango de valores, no obstante, es importante resaltar que en el presente trabajo se consideraron durante la realización de los experimentos la inclusión de situaciones comunes durante la conducción como son estrés, fatiga o la realización de actividades secundarias. Hasta nuestro conocimiento no hay trabajos previos que consideren estos estados cognitivos, por lo tanto, nuestros resultados contribuyen al estado del arte y muestran la detección de intención de frenado cuando los conductores experimentan

estas situaciones comunes.

En conclusión, este trabajo muestra la viabilidad de un enfoque neuro-ergonómico de asistencia en la conducción que permite reducir tiempos de respuesta detectando la intención de frenar antes de que cualquier acción de respuesta se haga observable. Esta viabilidad podría ser utilizada para el desarrollo de tecnología que mejoren las estrategias de interacción entre los sistemas autónomos de los vehículos y el conductor para mejorar la experiencia de manejo basada en un control cooperativo [43]. La contribución del trabajo radica en el diseño de la tarea experimental. En la literatura reciente [17], [19], [20], los experimentos se han llevado a cabo en entornos controlados en los cuales el participante se centra en la tarea de conducción o de frenado sin afrontar perturbaciones inherentes a la conducción real. Estas perturbaciones pueden afectar el comportamiento de la actividad cerebral del conductor durante una acción de frenado de emergencia. En el presente trabajo los participantes se enfrentaron a una representación más próxima al estado cognitivo y físico que se experimenta durante una verdadera situación de conducción. Por lo tanto, los resultados obtenidos indican la posibilidad de detectar la intención de frenado de emergencia en condiciones de conducción más realistas. No obstante, es conveniente examinar el efecto de estas situaciones en un ambiente de conducción real para establecer si existen diferencias en comparación a los resultados obtenidos en el ambiente simulado.

AGRADECIMIENTOS

Este estudio fue apoyado por el Consejo Nacional de Ciencia y Tecnología de México (CONACYT) a través de los proyectos 268958 y PN2015-873. Luis G. Hernández agradece a CONACYT por la beca otorgada para estudios de doctorado.

REFERENCIAS

- [1] Organización Mundial de la Salud, "Plan mundial para el decenio de acción para la seguridad vial 2011-2020," https://www.who.int/roadsafety/decade_of_action/es/, OMS, Tech. Rep., 2010.
- [2] World Health Organization, "Global status report on road safety 2013," https://www.who.int/violence_injury_prevention/road_safety_status/2013/en/, WHO, Tech. Rep., 2013.
- [3] R. Subramanian, *Motor Vehicle Traffic Crashes as a Leading Cause of Death in the United States, 2008 and 2009*. National Highway Traffic Safety Administration, 2012.
- [4] M. F. Allnutt, "Human factors in accidents," *BMJ Quality & Safety*, vol. 11, no. 4, pp. 369–374, 2002. [Online]. Available: <https://qualitysafety.bmj.com/content/11/4/369>
- [5] A. D. Horowitz and T. A. Dingus, "Warning signal design: A key human factors issue in an in-vehicle front-to-rear-end collision warning system," *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, vol. 36, no. 13, pp. 1011–1013, 1992. [Online]. Available: <https://doi.org/10.1177/0018720894036001320>
- [6] H. Summala and T. Mikkola, "Fatal accidents among car and truck drivers: Effects of fatigue, age, and alcohol consumption," *Human Factors*, vol. 36, no. 2, pp. 315–326, 1994, PMID: 8070795. [Online]. Available: <https://doi.org/10.1177/001872089403600211>
- [7] E. Petridou and M. Moustaki, "Human factors in the causation of road traffic crashes," *European Journal of Epidemiology*, vol. 16, no. 9, pp. 819–826, Sep 2000. [Online]. Available: <https://doi.org/10.1023/A:1007649804201>
- [8] National Highway Traffic Safety Administration, "Automotive collision avoidance system field operational test," U.S. Department of transportation, Tech. Rep., 2005.
- [9] A. Shaout, D. Colella, and S. Awad, "Advanced driver assistance systems - past, present and future," in *2011 Seventh International Computer Engineering Conference (ICENCO'2011)*, Dec 2011, pp. 72–82.
- [10] K. A. Brookhuis, D. D. Waard, and W. H. Janssen, "Behavioural impacts of advanced driver assistance systems: an overview," *European Journal of Transport and Infrastructure Research*, pp. 245–253, 2001.
- [11] A. Paul, R. Chauhan, R. Srivastava, and M. Baruah, "Advanced driver assistance systems," in *SAE Technical Paper*. SAE International, 02 2016. [Online]. Available: <https://doi.org/10.4271/2016-28-0223>
- [12] C. G. Quintero M., R. Medina U., and A. Tapia T., "Drivers characterization based on a signal analysis of vehicle telemetry," *IEEE Latin America Transactions*, vol. 15, no. 10, pp. 1840–1846, Oct 2017.
- [13] A. Pentland and A. Liu, "Modeling and prediction of human behavior," *Neural Computation*, vol. 11, no. 1, pp. 229–242, 1999. [Online]. Available: <https://doi.org/10.1162/089976699300016890>
- [14] H. Kopetz and S. Poledna, "Autonomous emergency braking: A system-of-systems perspective," in *2013 43rd Annual IEEE/IFIP Conference on Dependable Systems and Networks Workshop (DSN-W)*, June 2013, pp. 1–7.
- [15] H. Sherk and G. A. Fowler, "Chapter 16 neural analysis of visual information during locomotion," in *Vision: From Neurons to Cognition*, ser. Progress in Brain Research. Elsevier, 2001, vol. 134, pp. 247 – 264. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0079612301340177>
- [16] M. Saffarian, J. C. de Winter, and J. W. Senders, "Measuring drivers visual information needs during braking: A simulator study using a screen-occlusion method," *Transportation Research Part F: Traffic Psychology and Behaviour*, vol. 33, pp. 48 – 65, 2015. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1369847815001059>
- [17] S. Haufe, M. S. Treder, M. F. Gugler, M. Sagebaum, G. Curio, and B. Blankertz, "EEG potentials predict upcoming emergency brakings during simulated driving," *Journal of Neural Engineering*, vol. 8, no. 5, p. 056001, 2011. [Online]. Available: <http://stacks.iop.org/1741-2552/8/i=5/a=056001>
- [18] S. Haufe, J.-W. Kim, I.-H. Kim, A. Sonnleitner, M. Schrauf, G. Curio, and B. Blankertz, "Electrophysiology-based detection of emergency braking intention in real-world driving," *Journal of Neural Engineering*, vol. 11, no. 5, p. 056011, 2014. [Online]. Available: <http://stacks.iop.org/1741-2552/11/i=5/a=056011>
- [19] I.-H. Kim, J.-W. Kim, S. Haufe, and S.-W. Lee, "Detection of braking intention in diverse situations during simulated driving based on EEG feature combination," *Journal of Neural Engineering*, vol. 12, no. 1, p. 016001, 2015. [Online]. Available: <http://stacks.iop.org/1741-2552/12/i=1/a=016001>
- [20] P. Bouchner, J. Faber, S. Novotný, and T. Tichý, "Driver's attention level improvement with use of biofeedback stimulation incorporated into driving simulator," *Neural Network World*, vol. 19, no. 1, pp. 109 – 118, 2009.
- [21] T. Schweizer, K. Kan, Y. Hung, F. Tam, G. Naglie, and S. Graham, "Brain activity during driving with distraction: an immersive fmri study," *Frontiers in Human Neuroscience*, vol. 7, p. 53, 2013. [Online]. Available: <https://www.frontiersin.org/article/10.3389/fnhum.2013.00053>
- [22] B. Y. M. Lobato and A. A. Garza, "Classification algorithm for measuring human emotion: "i like it" and "i do not like" in neuromarketing," *IEEE Latin America Transactions*, vol. 15, no. 11, pp. 2177–2184, Nov 2017.
- [23] G. Borghini, L. Astolfi, G. Vecchiato, D. Mattia, and F. Babiloni, "Measuring neurophysiological signals in aircraft pilots and car drivers for the assessment of mental workload, fatigue and drowsiness," *Neuroscience & Biobehavioral Reviews*, vol. 44, pp. 58 – 75, 2014, applied Neuroscience: Models, methods, theories, reviews. A Society of Applied Neuroscience (SAN) special issue. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0149763412001704>
- [24] A. Wester, K. Böcker, E. Volkerts, J. Verster, and J. Kenemans, "Event-related potentials and secondary task performance during simulated driving," *Accident Analysis & Prevention*, vol. 40, no. 1, pp. 1 – 7, 2008. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0001457507000334>
- [25] B. Wymann, E. Espié, C. Guionneau, C. Dimitrakakis, R. Coulom, and A. Sumner, "TORCS, The Open Racing Car Simulator," <http://www.torcs.org>, 2014.
- [26] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, "Braincomputer interfaces for communication and control," *Clinical Neurophysiology*, vol. 113, no. 6, pp. 767 – 791,

2002. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1388245702000573>
- [27] J. Wolpaw and E. Wolpaw, *Brain-Computer Interfaces: Principles and Practice*. Oxford University Press, USA, 2012. [Online]. Available: <https://books.google.com/books?id=tC2UzuC\WBQC>
- [28] D. P. Subha, P. K. Joseph, R. Acharya U, and C. M. Lim, "Eeg signal analysis: A survey," *Journal of Medical Systems*, vol. 34, no. 2, pp. 195–212, Apr 2010. [Online]. Available: <https://doi.org/10.1007/s10916-008-9231-z>
- [29] R. Muñoz-Soto, R. Olivares, C. Taramasco, R. Villarroel, R. Soto, T. S. Barcelos, E. Merino, and M. F. Alonso-Sánchez, "Using black hole algorithm to improve eeg-based emotion recognition," *Comp. Int. and Neurosc.*, vol. 2018, pp. 3 050 214:1–3 050 214:21, 2018. [Online]. Available: <https://doi.org/10.1155/2018/3050214>
- [30] R. Chepesiuk, "Decibel hell: The effects of living in a noisy world," *Environmental Health Perspectives*, vol. 113, no. 1, pp. A34–A41, 2005. [Online]. Available: <https://ehp.niehs.nih.gov/doi/abs/10.1289/ehp.113-a34>
- [31] G. Borghini, G. Vecchiato, J. Toppi, L. Astolfi, A. Maglione, R. Isabella, C. Caltagirone, W. Kong, D. Wei, Z. Zhou, L. Polidori, S. Vitiello, and F. Babiloni, "Assessment of mental fatigue during car driving by using high resolution EEG activity and neurophysiologic indices," in *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Aug 2012, pp. 6442–6445.
- [32] A. Maglione, G. Borghini, P. Aricò, F. Borgia, I. Graziani, A. Colosimo, W. Kong, G. Vecchiato, and F. Babiloni, "Evaluation of the workload and drowsiness during car driving by using high resolution EEG activity and neurophysiologic indices," in *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Aug 2014, pp. 6238–6241.
- [33] S. Baulk, L. Reyner, and J. Horne, "Driver sleepiness evaluation of reaction time measurement as a secondary task," *Sleep*, vol. 24, no. 6, pp. 695–698, 2001. [Online]. Available: <http://dx.doi.org/10.1093/sleep/24.6.695>
- [34] J. A. Horne and S. D. Baulk, "Awareness of sleepiness when driving," *Psychophysiology*, vol. 41, no. 1, pp. 161–165, 2004. [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1046/j.1469-8986.2003.00130.x>
- [35] Y. Komada, S. Asaoka, T. Abe, and Y. Inoue, "Short sleep duration, sleep disorders, and traffic accidents," *IATSS Research*, vol. 37, no. 1, pp. 1 – 7, 2013. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S038611213000149>
- [36] I. Guyon and A. Elisseeff, "An introduction to variable and feature selection," *J. Mach. Learn. Res.*, vol. 3, pp. 1157–1182, Mar. 2003. [Online]. Available: <http://dl.acm.org/citation.cfm?id=944919.944968>
- [37] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification (2Nd Edition)*. New York, NY, USA: Wiley-Interscience, 2000.
- [38] R. Vega, T. Sajed, K. W. Mathewson, K. Khare, P. M. Pilarski, R. Greiner, G. Sánchez-Ante, and J. M. Antelis, "Assessment of feature selection and classification methods for recognizing motor imagery tasks from electroencephalographic signals," *Artificial Intelligence Research*, vol. 6, no. 1, p. 37, 2017. [Online]. Available: <http://www.sciedu.ca/journal/index.php/air/article/view/9839>
- [39] F. Lotte, L. Bougrain, A. Cichocki, M. Clerc, M. Congedo, A. Rakotomamonjy, and F. Yger, "A review of classification algorithms for EEG-based braincomputer interfaces: a 10 year update," *Journal of Neural Engineering*, vol. 15, no. 3, p. 031005, 2018. [Online]. Available: <http://stacks.iop.org/1741-2552/15/i=3/a=031005>
- [40] A. F. Vidal, M. A. Oliver, and G. Lopez, "Development of a brain-computer interface based on visual stimuli for the movement of a robot joints," *IEEE Latin America Transactions*, vol. 14, no. 2, pp. 477–484, Feb 2016.
- [41] C. M. Bishop, *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Berlin, Heidelberg: Springer-Verlag, 2006.
- [42] E. Combrisson and K. Jerbi, "Exceeding chance level by chance: The caveat of theoretical chance levels in brain signal classification and statistical assessment of decoding accuracy," *Journal of Neuroscience Methods*, vol. 250, pp. 126 – 136, 2015, cutting-edge EEG Methods. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0165027015000114>
- [43] O. Garcia, G. B. Vitor, J. V. Ferreira, P. S. Meirelles, and A. de Miranda Neto, "The vilma intelligent vehicle: an architectural design for cooperative control between driver and automated system," *Journal of Modern Transportation*, vol. 26, no. 3, pp. 220–229, Sep 2018. [Online]. Available: <https://doi.org/10.1007/s40534-018-0160-3>



Luis G. Hernández Estudiante de doctorado en Ciencias de Ingeniería y asistente de investigación en el Laboratorio de Neurotecnología e interfaces cerebro computador (NTLab) del Tecnológico de Monterrey. Su área de investigación aborda técnicas para estudiar la actividad cerebral utilizando señales electroencefalográficas, procesamiento de señales electrofisiológicas, inteligencia computacional, ciencia de datos e instrumentación para aplicaciones biomédicas.



Efraín Martínez Ingeniero electrónico y de comunicaciones, M.Sc. con especialidad en Ingeniería Electrónica (Sistemas Electrónicos) del Tecnológico de Monterrey. Su área de investigación es sistemas microelectrónicos embebidos y circuitos integrados de propósito específico, lenguajes de programación, lenguajes descriptores de hardware (HDL).



Javier M. Antelis Profesor-investigador de la Escuela de Ingeniería y Ciencias y director del Laboratorio de Neurotecnología e interfaces cerebro computador (NTLab) del Tecnológico de Monterrey. Su área de investigación se centra en el estudio e interpretación de la actividad eléctrica del cerebro humano adquirida con la técnica de electroencefalograma. Sus temas de investigación incluyen el procesamiento digital de señales, teoría de estimación y detección, métodos bayesianos, decodificación de estados cognitivos a partir de registros electrofisiológicos, instrumentación y ciencia de datos para aplicaciones biomédicas y astrofísicas.