

# Informe final

## Metodología de intervención del entorno de conducción en base a identificación de fatiga, estrés y carga cognitiva mediante bioseñales

### AUTORES

CRISTIAN RETAMAL  
FRANCISCO DÍAZ  
ÁNGEL JIMÉNEZ

### CONTACTO IST

FRANCISCO MIRANDA  
KARINA ARELLANO

## Resumen

Este informe es el último de una serie de cuatro del proyecto de investigación SUSESO "Metodología de Intervención del Entorno de Conducción en base a Identificación de Fatiga, Estrés y Carga Cognitiva Mediante Bioseñales", patrocinado por el Instituto de Seguridad del Trabajador (IST) y realizado por el Instituto Sistemas Complejos de Ingeniería (ISCI), centro de excelencia alojado en la Facultad de Ciencias Físicas y Matemáticas de la Universidad de Chile.

Este informe reporta los resultados de los tres objetivos específicos del proyecto. En primer lugar se presenta una revisión sistemática de la literatura científica acerca de los conceptos de carga cognitiva, estrés y fatiga/somnolencia en el contexto de la conducción. Además, se reporta el estado de la literatura en relación a actuadores de intervención del ambiente del conductor. Aunque no es parte de este proyecto, se resumen los resultados obtenidos en un proyecto anterior, para proveer el contexto necesario del estudio. Para ello, se describe un modelo de clasificación de la fatiga que experimentan conductores de buses en una ruta de alta montaña, basando el análisis en el procesamiento de señales psicofisiológicas.

Como parte del primer objetivo específico, se muestran los resultados de caracterización de la carga cognitiva de conductores de buses de la misma ruta de alta montaña, por medio del análisis estadístico y pruebas de hipótesis sobre sus señales psicofisiológicas. En relación al segundo objetivo específico, se presenta el desarrollo de una metodología experimental para el estudio en un simulador de conducción del comportamiento del estrés de conductores de las mismas características, enfrentados a eventos inesperados de la ruta. Tales eventos no es posible inducirlos en una ruta real por razones éticas y de seguridad, por lo cual se optó por estudiar sus efectos en el estrés de los conductores utilizando un simulador de conducción. Además, se presentan los resultados de la caracterización del estrés inducido por medio de biomarcadores significativos obtenidos del análisis de las señales psicofisiológicas.

Finalmente se describen los resultados de un estudio experimental para identificar actuadores que afecten significativamente el estado de fatiga del

conductor. Para ello se describe un experimento de conducción por la ciudad de Santiago en una ruta predefinida de una duración aproximada de tres horas, comparando biomarcadores específicos de las señales psicofisiológicas de dos grupos de conductores sometidos a diferentes intervenciones.

## **Keywords**

Carga cognitiva, estrés, fatiga, conducción, simulador de conducción, intervenciones del entorno de conducción.

## Control de actualizaciones del documento

Versión	Fecha	Descripción de la modificación
01	30-09-2020	Estado del arte carga cognitiva, estrés y fatiga en conducción
02	30-11-2020	Incorporación resultados prueba de hipótesis
03	27-04-2021	Experimento en simulador y propuesta de intervenciones
04	30-09-2021	Ejecución de experimento de intervenciones en terreno
05	15-12-2021	Análisis datos intervenciones, conclusiones finales
06	23-12-2021	Cierre informe final

## Información Institucional

### **Autores**

Cristian Retamal<sup>1,2</sup>, <cristian.retamal@ug.uchile.cl>, Ingeniero del Proyecto.  
Francisco Díaz<sup>1,2</sup>, <francisco.diaz.g@ug.uchile.cl>, Director Alterno del Proyecto.  
Ángel Jiménez<sup>1,2,3</sup>, <ajimenez@dii.uchile.cl>, Director del Proyecto.

<sup>1</sup>Instituto Sistemas Complejos de Ingeniería (ISCI), <http://www.isci.cl>

<sup>2</sup>Web Science and Smart Technologies Lab (Wesstlab), <http://wesstlab.dii.uchile.cl>

<sup>3</sup>Facultad de Ciencias Físicas y Matemáticas, Departamento de Ingeniería Industrial, Universidad de Chile.

### **Contacto en IST**

Francisco Miranda, <francisco.miranda@ist.cl>  
Instituto de Seguridad del Trabajo (IST), <http://www.ist.cl>

### **Proyecto**

Metodología de intervención del entorno de conducción en base a identificación de fatiga, estrés y carga cognitiva mediante bioseñales.

Proyectos de investigación e innovación en prevención de accidentes del trabajo y enfermedades profesionales.

Superintendencia de Seguridad Social (SUSESO), <http://www.suseso.cl>

# Índice

<b>1. Introducción</b>	<b>1</b>
<b>2. Estado del arte</b>	<b>3</b>
2.1. Metodología de revisión bibliográfica . . . . .	3
2.2. Medición de estados psicofisiológicos . . . . .	7
2.3. Enfoques de análisis de datos . . . . .	12
2.4. Carga Cognitiva en conducción . . . . .	14
2.5. Estrés en conducción . . . . .	32
2.6. Fatiga en conducción . . . . .	46
2.7. Definiciones y constructos seleccionados . . . . .	58
2.8. Interacción entre los estados psicofisiológicos . . . . .	60
2.9. Intervenciones del entorno . . . . .	63
<b>3. Detección de fatiga en conducción</b>	<b>71</b>
3.1. Descripción de la tarea . . . . .	71
3.2. Sensores y Dispositivos . . . . .	71
3.3. Participantes . . . . .	72
3.4. Método experimental . . . . .	72
3.5. Modelos de detección de fatiga . . . . .	73
3.6. Resultados . . . . .	74
<b>4. Detección de carga cognitiva en conducción</b>	<b>75</b>
4.1. Desarrollo de las etiquetas . . . . .	75
4.2. Métodos estadísticos implementados . . . . .	81
4.3. Resultados . . . . .	81
<b>5. Detección de estrés en conducción</b>	<b>85</b>
5.1. Experimentos en simulador . . . . .	85
5.2. Participantes . . . . .	86
5.3. Sensores y dispositivos . . . . .	87
5.4. Metodología de experimentación . . . . .	87
5.5. Consolidación y resumen de datos . . . . .	91
5.6. Análisis de datos y resultados . . . . .	97

<b>6. Análisis de intervenciones en conducción</b>	<b>104</b>
6.1. Uso de intervenciones . . . . .	104
6.2. Criterios de selección de intervenciones . . . . .	105
6.3. Intervenciones propuestas . . . . .	106
6.4. Diseño experimental de validación de intervenciones . . . . .	110
6.5. Datos capturados . . . . .	116
6.6. Análisis y resultados . . . . .	124
<b>7. Conclusiones</b>	<b>131</b>
<b>8. Anexos</b>	<b>135</b>
8.1. Tablas de análisis estadístico por eventos de características psicofisiológicas para estrés en simulador . . . . .	135
8.2. Tablas de análisis estadístico por eventos de métricas del vehículo para estrés en simulador . . . . .	139
<b>References</b>	<b>141</b>

# 1. Introducción

Se estima que a nivel mundial 1.35 millones de personas mueren en accidentes de transporte cada año. Además, los accidentes de tráfico representan en su totalidad un costo cercano al 3 % del PIB en la mayoría de los países. En Chile, la cifra de fallecidos asciende a 1.617 para el año 2018, y los accidentes de tránsito representaron un costo de 2.1 % del PIB [130]. Según la comisión nacional de seguridad de tránsito [129], para el año 2018 el 49 % del accidente fatales de trabajo fue asociado a la presencia de un vehículo, de los cuales 87 % corresponden a accidentes en vía pública. Por lo tanto, la alta tasa de accidentabilidad en este ámbito subraya la importancia de crear métodos para su reducción.

Los factores causales más tradicionales de accidentes de tránsito son el exceso de velocidad, la ingesta de alcohol o sustancias psicoactivas, el no uso de elementos de protección y la inseguridad de los vehículos y carreteras. Además, hoy en día han cobrado especial relevancia otros factores que son propios de cada conductor. Entre ellos se destacan la carga cognitiva, la fatiga y el estrés. Los primeros dos ya han sido nombrados por autoridades competentes en el área, por ejemplo, en el informe de seguridad anual del año 2017 [76]. Múltiples estudios en diferentes países muestran que la prevalencia de la fatiga en la incidencia de accidentes de tránsito bordea el 20 % [25, 51, 169]. La importancia que varios países otorgan a estos factores, ha llevado al desarrollo de campañas de prevención contra la fatiga y la distracción al volante [24, 35, 36].

La fatiga se relaciona con la pérdida de eficiencia en el desempeño de una tarea y la aversión a cualquier tipo de esfuerzo presentado luego de una sobrecarga, ya sea física o mental, relacionándose frecuentemente a un tiempo prolongado de actividad. En la conducción se asocia con la somnolencia, la cual se refiere a la transición entre la vigilia y el sueño. Ésta provoca reducción en los tiempos de respuesta de la persona, alteración de la frecuencia de sus parpadeos y bostezos, y limita la tolerancia al ejercicio a través de una mayor percepción de esfuerzo. Ante un evento inesperado en la ruta o frente a la toma de decisiones correctas para un óptimo rendimiento, estas conductas pueden resultar perjudiciales.

La alta carga cognitiva se relaciona principalmente con la inatención, atención

dividida entre más de una tarea o distracción de los conductores en la tarea principal. Esto provoca que el rendimiento se deteriore y que existan faltas de vigilancia ante la demanda específica de la tarea. Por otro lado, una baja carga cognitiva conlleva al aburrimiento, estado perjudicial para la toma de respuestas oportunas ante eventos inesperados. Campañas que incentiven al menor uso de dispositivos electrónicos mientras se conduce han permitido una disminución de la carga cognitiva como factor de riesgo, sin embargo, no resulta ser suficiente.

El estrés se presenta en mayor medida en la actividad de conducción en relación a diversos estímulos, como eventos inesperados y altos niveles de ruido. Estos eventos, además de las actividades dentro de cada vehículo, actúan como estresores que llevan a que las personas vean interrumpida su concentración, desencadenando acciones peligrosas como, por ejemplo, el aumento de la agresividad y el peligro, además de una menor atención a las situaciones de tráfico. De igual manera, las personas que frecuentemente se ven enfrentadas a tareas de conducción son más propensas a daños de largo plazo, como lo son el estrés crónico y sus diferentes síntomas asociados [8, 9].

Aunque las campañas preventivas desarrolladas en diferentes localidades han demostrado eficacia en la disminución de accidentes, no se ha logrado la eliminación de estos factores de riesgo en la conducción de manera completa. Es por ello que la investigación actual se dirige hacia la detección de estados conductuales perjudiciales a partir de metodologías basadas en señales psicofisiológicas de cada individuo.

En el presente informe, correspondiente a la continuación del primer informe del proyecto “Metodología de intervención del entorno de conducción en base a identificación de fatiga, estrés y carga cognitiva mediante bioseñales”, se exponen los principales resultados de modelos de detección de fatiga y análisis estadísticos de estados de carga cognitiva, desarrollados sobre un experimento ya implementado sobre conducción real de conductores de buses, además de la elaboración de un protocolo experimental para la detección de estrés y carga cognitiva de conductores en ambientes de simulación.

## **2. Estado del arte**

En esta sección se presenta la revisión bibliográfica del estado del arte relacionado a los eventos de fatiga, carga cognitiva y estrés en la conducción realizada, enfocándose principalmente en las definiciones de estos conceptos que se plantean en la literatura y en los principales métodos de medición junto con las intervenciones del entorno posibles para mitigar los efectos adversos generados por estos eventos.

Primero, se expone la metodología utilizada para la revisión bibliográfica como las palabras clave o *keywords* escogidas para la búsqueda y los criterios para categorizar la revisión. Luego, como marco conceptual, se presentan los métodos generales de medición psicofisiológica y los modelos frecuentemente usados para su análisis. A continuación, se discuten las definiciones, efectos en la conducción, métodos de estimación y de análisis más específico para la fatiga, la carga cognitiva y el estrés con lo que se propone un framework de interacción de estos tres estados. Finalmente, se presenta el análisis de la literatura sobre las intervenciones del entorno posibles en la conducción, las categorías y criterios existentes.

### **2.1. Metodología de revisión bibliográfica**

Dada la basta cantidad de información existente, se plantea un procedimiento sistemático de revisión bibliográfica. Para ello, se seleccionan algunas de las principales editoriales científicas del mundo como fuentes de artículos, a saber: IEEE, Springer, Science Direct, ACM, Sage, Pumbed, MDPI y Frontiers. Para cada una de ellas, se hacen consultas a sus buscadores con términos claves relevantes para este trabajo. Posteriormente, se seleccionan los resultados de manera manual, a partir de la información que poseen en la sección abstract, considerando aquellos estudios que coinciden con nuestros criterios de búsqueda. En particular, se buscan estudios relacionados a la predicción o clasificación de carga cognitiva y estrés a partir de diferentes fuentes de datos medibles. Para el caso de fatiga se buscan artículos de revisión bibliográfica (surveys), y se realiza un análisis de las referencias encontradas en ellos.

### 2.1.1. Fatiga en conducción

Las búsquedas realizadas en relación a la fatiga en conducción se detallan a continuación:

- **IEEE:** Para la búsqueda se escogen los términos claves “Fatigue Driving” o “Driver Fatigue”.
- **Science Direct:** Se utilizan los términos claves “Driver fatigue” y “driving fatigue” y “detection”.
- **ACM:** Se hacen búsquedas de las palabras claves “fatigue driving” o “driver fatigue” y que el abstract tenga la palabra “driv\*”, para fechas de publicación entre el 2010 y 2020.
- **Springer:** Se hacen búsquedas de estudios cuyos títulos posean “driv\* fatigue” y el contenido la palabra “sensor”.
- **Sage:** Se hace una combinación de búsqueda entre palabras claves (“driving” y “fatigue” o “fatigue”) y palabras en los títulos (“fatigue”) y en el abstract (“driv\*”).
- **Pubmed:** Se hace una combinación entre búsqueda de palabras claves en el título (“fatigue” y “driving” o “driver” o “drive”) y palabras claves en el título o abstract (“detection” o “prediction”).
- **MDPI:** Se buscan las palabras claves “fatigue driving” o “driver fatigue” o “driving fatigue” en los títulos de los estudios.
- **Frontiers:** Se realiza una exploración manual seleccionando los primeros 20 estudios acerca del tema.

De los estudios encontrados se seleccionan aquellos correspondientes a surveys o estados del arte. Se selecciona manualmente un conjunto de referencias presentes en estos estudios, obteniendo un total de 55 artículos científicos a considerar. Se realiza de esta manera debido a que el tema de fatiga en la conducción se ha analizado profusamente en la literatura.

### 2.1.2. Carga cognitiva en conducción

Las búsquedas realizadas con el tema de carga cognitiva en conducción se detallan a continuación:

- **IEEE:** Se busca una combinación entre palabras en el título (“workload” y “driv\*”) y palabras claves en el abstract (“detection” o “prediction”).
- **Science Direct:** Se buscan las palabras claves que se presenten en el título, abstract o keywords (“driver” o “driving”) y (“detection” o “prediction”).
- **ACM:** Se busca la combinación de palabras claves en el título (“workload” y “driv\*”) y en el abstract (“cognitive”) con fechas de publicación entre el 2010 y 2020.
- **Springer:** Se buscan las palabras claves “cognitive” y (“prediction” o “detection”).
- **Sage:** Se buscan las palabras claves en los títulos “workload” y “driv\*”.
- **Pubmed:** Se buscan las palabras claves en los títulos “workload” y “driv\*”.
- **MDPI** Se buscan las palabras claves en los títulos “workload” y “driving”.

Luego de la selección manual de estudios relevantes se obtiene un total de 46 artículos científicos a considerar.

### 2.1.3. Estrés en conducción

Las búsquedas realizadas para estrés en conducción se detallan a continuación:

- **IEEE:** Se hace una combinación entre palabras claves en el título (“driv\*”) y en el abstract (“driv\*”) y en todo el documento (“Stress Detection”) y que no posean los términos clave (“mechanical” y “electric”).
- **Science direct:** Palabras clave en el título (“driver” o “driving”) y “Stress detection” que no posean los términos clave (“mechanical”, “history”).
- **ACM :** Palabras clave en el título “stress” o “driv\*” con fecha de publicación entre el 2010 y 2020.

- **Springer:** Búsqueda con palabras clave (“Driver stress” o “Driving stress”) y (“detection” o “prediction”) que no posea el término clave “chemistry”.
- **Sage:** Búsqueda con las palabras claves en el título “stress” y “driving”.
- **Pubmed:** Búsqueda con la palabra clave “detection” y palabras claves en el título “stress” y (“driving” o “driver”).
- **MDPI:** Búsqueda de palabras claves en el título “stress” y “drive”.

Luego de la selección manual de estudios relevantes se obtiene un total de 41 artículos científicos a considerar.

#### 2.1.4. Categorías de la revisión

Para realizar un análisis metodológico de los artículos, estos se categorizan de acuerdo a los siguientes criterios:

- **Muestra experimental:** Se considera el número de participantes a evaluar y si representa un número significativo para las conclusiones obtenidas.
- **Ambiente de conducción:** Es interesante notar que inducir los estados psicofisiológicos a evaluar al momento de manejar un vehículo puede ser muy peligroso, por lo que muchos estudios utilizan la estrategia de simulación. Sin embargo, esto último presenta la desventaja que el participante conoce que está en un ambiente protegido, por lo que sus reacciones pueden ser diferente a las reacciones que realizaría en un ambiente real.
- **Inducción del estado psicofisiológico:** Un aspecto importante a considerar en cada estudio es la manera de inducir el estado psicofisiológico a evaluar o, en otros casos, conocer los momentos exactos que se catalogarán como pertenecientes a niveles más altos o más bajos para un determinado estado. En particular, se pueden encontrar diferentes estrategias tales como identificar eventos propios de la acción de los conductores o de la conducción, o inducir el estado psicofisiológico en base a una tarea secundaria o eventos forzados en la ruta.

- **Modelos de inteligencia computacional:** En los estudios existen diferentes maneras de argumentar los efectos de la presencia de un determinado estado psicofisiológico en la conducción, por lo cual se consideran los modelos reportados dentro de las categorías de modelos predictivos, de clasificación o inferencias estadísticas.
- **Fuentes de datos:** Finalmente, para cada estudio se considera el tipo de dato a partir del cual se infiere o evalúa el estado psicofisiológico. Estos pueden ser de diferentes fuentes como las señales psicofisiológicas, el rendimiento de conductor o medidas subjetivas autorreportadas (ver 2.2).

Previo a entrar de lleno en el análisis del estado del artes, haremos un repaso por el marco contextual necesario para comprender este estudio. Para ello, definiremos de aquí en adelante la fatiga, la carga cognitiva y el estrés como *estados psicofisiológicos* pues nuestro interés es estudiar estos fenómenos desde el punto de vista de la psicofisiología, es decir, estudiar las bases biológicas de la conducta humana y los procesos psicológicos generados de ellos.

En las siguientes dos secciones se analiza el marco contextual concerniente a la medición de estados psicofisiológicos y a los modelos frecuentemente utilizados para su análisis.

## **2.2. Medición de estados psicofisiológicos**

A continuación, se presenta el marco conceptual sobre los métodos actuales de medición de estados psicofisiológicos. En secciones posteriores se presenta cómo se utilizan para medir los estados específicos de carga cognitiva, estrés y fatiga.

### **2.2.1. Señales Psicofisiológicas**

El sistema nervioso se divide en el Sistema Nervioso Central (SNC), formado por el encéfalo y la médula espinal; el Sistema Nervioso Somático, encargado de los receptores sensoriales y movimientos voluntarios y el Sistema Nervioso Autónomo (SNA) que regula las acciones involuntarias que se subdivide en el sistema simpático (SNS) y parasimpático (PNS).

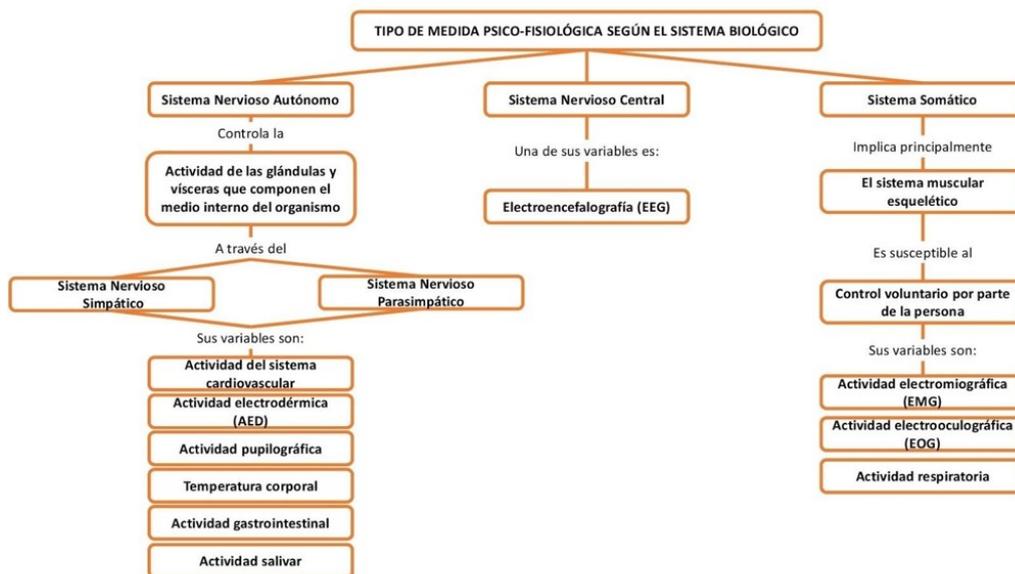


Figura 2.1: Mapa conceptual de medidas psicofisiológicas del sistema nervioso.

Tanto las señales generadas por el SNC como por el SNA, que son manifestaciones periféricas de procesos internos gobernados por el SNC, pueden ser registradas mediante diversos biosensores. Estos registros de la actividad del sistema nervioso se denominan señales psicofisiológicas. En la Figura 2.2.1 se observa que existen diferentes medidas psicofisiológicas relacionadas con las distintas componentes del sistema nervioso.

El registro de estas señales pueden verse influidas por el estado psicofisiológico y físico de la persona, como también por características del ambiente, como movimiento o campos electromagnéticos.

Hoy en día, los avances tecnológicos han permitido que los biosensores sean cada vez más pequeños, portables y ergonómicos haciendo posible registrar medidas psicofisiológicas sin interferir mayormente con la actividad que esté realizando el sujeto.

A continuación, se explican brevemente las principales señales psicofisiológicas de interés para la medición de estados psicofisiológicos:

- **Electrocardiograma (ECG):** Esta medida se registra con un electrocardiógrafo que consiste en tres o más electrodos ubicados sobre la piel para la detección de corrientes eléctricas que se irradian a través del tejido circun-

dante al corazón, debido a su actividad eléctrica. Cuando el corazón se contrae existe una estimulación que genera una despolarización del miocardio. Cuando se encuentra en relajación ocurre una repolarización. Las señales adquiridas se transforman en formas de onda que representan este ciclo cardiaco. Este proceso corresponde a los eventos que ocurren desde un latido del corazón hasta el siguiente y está compuesto por dos etapas principales: diástole, durante la cual el corazón se llena de sangre y sístole, cuando el corazón bombea toda esa sangre al cuerpo. En general, el ECG es utilizado para calcular el ritmo cardiaco (HR), es decir, la cantidad de latidos por minuto, u otras medidas como la variabilidad del ritmo cardiaco (HRV), correspondiente a la oscilación en el intervalo temporal entre dos latidos consecutivos del corazón. Además, dada la forma de la señal, también puede ser usada directamente mediante tratamiento de señales tales como detección de peaks u otras características.

- **Electroencefalografía (EEG):** El cerebro genera actividad continuamente, incluso en ausencia de estímulos, por ejemplo, al dormir. Esta actividad se mide con un electroencefalógrafo, un instrumento que utiliza electrodos ubicados en el cuero cabelludo para medir la tensión resultante de los flujos de corriente iónica dentro de las neuronas del cerebro producidos por la actividad sináptica cerebral. Dependiendo del modelo de electroencefalógrafo, existen diferentes distribuciones de electrodos, algunas con mayor complejidad, los cuales en general se dividen en las regiones lóbulo frontal, temporal, occipital o central. Un tipo de análisis bastante usado en la literatura corresponde al análisis de bandas de frecuencias, los cuales son útiles en estudios de estados cognitivo-afectivos. Este análisis se basa en que la señal obtenida de la EEG es una superposición de ondas de varias frecuencias, que se consideran un reflejo de cierto estado cognitivo, afectivo o atencional. En general, en su descomposición se consideran 5 bandas de frecuencia: Banda Delta (1-4 Hz), Theta (4-8 Hz), Alfa (8-12 Hz), Beta (12-25 Hz) y Gamma (>25 Hz).
- **Fotopleletismografía (PPG):** También conocida como pulso de volumen sanguíneo (Blood Volume Pulse, BVP), permite conocer el volumen de un

cuerpo estableciendo la cantidad de luz que absorbe y refleja. Es usado para estudiar el conducto vascular, midiendo el cambio del volumen sanguíneo ocasionado por el bombeo del corazón. Esta señal, al igual que el ECG, puede ser utilizada directamente para el análisis, aunque en general se usa para obtener la señal de ritmo cardiaco (HR) y sus características derivadas.

- **Respuesta electro-dérmica (EDA):** La respuesta galvánica de la piel (GSR, en inglés), también conocida como actividad electrodermal (EDA, en inglés), es una medida de la conductividad de la piel humana que se obtiene a través de dos electrodos adheridos a una zona con gran actividad sudorípara, generalmente la zona palmar de la mano o los dedos, e incluso la planta del pie. La conductividad varía según los cambios de humedad de la piel, relacionado con los cambios en la sudoración del usuario. La respuesta electrodérmica posee dos componentes. La componente tónica o nivel de conductancia (Skin conductance level, SCL), que presenta variaciones lentas y cambia constantemente dentro del individuo, dependiendo de su hidratación, sequedad de la piel o regulación autonómica y la componente fásica o respuesta de conductancia (Skin Conductance Response, SCR), la cual acompaña a los cambios tónicos alterándose más rápido. Esta última es sensible a eventos específicos de un estímulo que aparecen emocionalmente, mediante alzas bruscas que ocurren entre 1 y 5 segundos después de la aparición de los estímulos emocionales.
- **Temperatura corporal:** La temperatura de la piel (en inglés Skin Temperature, SKT) puede ser medida a partir de diferentes aparatos. La temperatura axilar en general es medida con un instrumento de contacto, mientras que la temperatura facial puede ser medida por cámaras térmicas o termómetros infrarrojos. Dependiendo de los eventos a estudiar, se pueden requerir diferentes instrumentos, ya sea midiendo la temperatura periférica o buscando una medida más centralizada.
- **Actividad pupilográfica:** Corresponde a la medición de los cambios en el tamaño de la pupila que pueden ocurrir debido a estímulos cognitivos, estímulos emocionales o estímulos ambientales. Esta medida puede verse afectada por la iluminación ambiental por lo cual su uso debe realizarse

en situaciones de iluminación controlados o con métodos de filtrado que consideren estos aspectos. En general, el tamaño pupilar ha sido fuertemente utilizado como medición de la carga cognitiva. Su medición se basa en el uso de instrumentos de registro ocular como los *eye Tracker*.

- **Actividad Electromiográfica (EMG):** Mide la actividad eléctrica generada por la contracción muscular corporal, pudiendo evaluar la relajación o activación que tiene un individuo. Para ello, se utilizan electrodos adheridos a la piel para traducir las señales eléctricas que se transmiten desde las neuronas motoras a los músculos al momento de la contracción, en valores numéricos interpretables. Instrumentos más invasivos utilizan agujas insertadas en cada uno de los músculos a evaluar.
- **Actividad Electrooculográfica (EOG):** Registra los movimientos oculares a partir de pequeños electrodos cerca de los músculos de los ojos. En general, existen cuatro movimientos oculares controlados por un sistema neural distinto cada uno, pero que llegan todos a los músculos extraoculares. Estos son: movimientos sacádicos, movimientos suaves de persecución, movimientos vestibulares y movimientos de convergencia.
- **Actividad respiratoria:** En general, se utilizan instrumentos que midan el volumen en la zona intercostal y abdominal del individuo, que permitan conocer la tasa de respiración u otras medidas relacionadas, como es el caso de los cinturones respiratorios. En algunos estudios la tasa de respiración puede ser medida a partir de un observador, aunque existen instrumentos más sofisticados como los espirómetros o los instrumentos de pulsioximetría que calculan estas medidas, pero que pueden resultar más invasivos.

### 2.2.2. Medidas de Rendimiento

Este enfoque busca estimar los estados psicofisiológicos de manera indirecta calculando el rendimiento directamente de la tarea principal, o bien, de una tarea secundaria que se ejecuta junto con la tarea principal.

Tomando el caso de la tarea de la conducción, en general, en el primer caso

se mide el rendimiento a partir de características registradas del vehículo, por ejemplo, la velocidad de conducción o la distancia al centro del carril. Para el segundo caso, los investigadores son los que definen qué métricas son útiles dependiendo de las tareas secundarias que desarrollan, por ejemplo, el número de aciertos o tiempos de reacción a determinadas actividades. La ventaja de este método es que es poco invasivo para el conductor en la mayor parte de la conducción. Su principal desventaja es que se ve afectado fuertemente por las características ambientales, tales como el tráfico o el estado de la carretera.

### **2.2.3. Medidas subjetivas**

Las medidas subjetivas buscan estimar los estados a través de la consulta directa del participante a través de cuestionarios o escalas de auto calificación. Existe una gran variedad de instrumentos específicos para cada estado que han sido estudiados y validados. La ventaja de este método es que permite generar resultados de algunos conceptos subjetivos difícil de definir de una manera sencilla. La desventaja es que el hecho de preguntar directamente genera una actividad extraña que puede interferir o hasta modificar el estado que se quiere medir. Además, preguntar dichos factores posterior a la prueba involucra la necesidad recuerdo de cada persona lo cual es difícil argumentar que sea un proceso perfecto. Al mismo tiempo, se asume que entre participantes los conceptos preguntados deben ser de común entendimiento.

## **2.3. Enfoques de análisis de datos**

Existe una amplia variedad de enfoques para el análisis de datos, unos usados más que otros dependiendo del dominio del estudio. A continuación, se presentan los dos enfoques utilizados en esta investigación: Las pruebas estadísticas y los modelos de clasificación.

### **2.3.1. Pruebas estadísticas**

Una prueba estadística es una forma de evaluar la evidencia que los datos proporcionan para probar una hipótesis. Esta hipótesis se denomina hipótesis nula, que normalmente se opone a una hipótesis denominada hipótesis

alternativa. El objetivo de las pruebas de significancia estadística es calcular el valor  $p$ , que es la probabilidad de que la hipótesis nula sea cierta.

Frecuentemente los estudios consideran la variación de señales al momento de presentarse un evento, por ejemplo, cuando el sujeto conduce bajo los efectos del estrés, carga cognitiva o fatiga, en comparación a los casos en que el evento no ocurre. Para asegurar que estos eventos realmente afectan dichas características, no basta con analizar los números en crudo, sino que es necesario un método que evidencie la significancia estadística en dichos cambios. Por esta razón, se ha considerado este enfoque en distintos estudios para obtener sus conclusiones. Dentro de las pruebas usadas están: Análisis de la varianza (ANOVA), Prueba F de Fisher o la prueba de los rangos con signo de Wilcoxon.

### **2.3.2. Modelos de clasificación**

Otra manera de entender las relaciones ente ciertas variables y los eventos relevantes es utilizando modelos de clasificación. En este caso, se evidencia que matemáticamente es posible estimar el tipo de evento relevante en función de señales medibles y por lo tanto, concluir que dichas variables son de utilidad o desde otra perspectiva, presentan cambios característicos entre las diferentes categorías o clases que se desea analizar.

Los modelos de clasificación se basan en métodos de aprendizaje de máquinas, también conocido como *machine learning*, cuya entrada son características calculadas a partir de las señales medibles. Por ejemplo, al utilizar la señal de ritmo cardiaco, se puede calcular la variabilidad del ritmo cardiaco como medida a analizar. Algunos ejemplos de modelos de clasificación son la regresión lineal,  $k$  vecinos más cercanos (kNN) máquina de vector de soportes (SVM) y redes neuronales artificiales (NN). De igual manera es posible utilizar métodos de *deep learning*, los cuales son una subcategoría del machine learning. En estos casos, los modelos pueden ser alimentados con características de las señales o directamente con las señales procesadas. De los métodos de deep learning se destaca la Red Neuronal Convolutiva (CNN) usadas principalmente para analizar imágenes, por ejemplo, usadas para analizar las imágenes del rostro del conductor para clasificar sus momentos de somnolencia.

## **2.4. Carga Cognitiva en conducción**

### **2.4.1. Definiciones**

La carga cognitiva es un proceso complejo, ampliamente estudiado por varios años. Aunque no se ha descrito una definición exacta de este fenómeno, en general, se entiende como el nivel de esfuerzo mental inducido en una persona por la tarea en la que se encuentra involucrada.

Una manera de explicar la carga cognitiva es a través del modelo de recursos cognitivos múltiples de Wickens [134] que supone la existencia de tres tipos de recursos de capacidad limitada, para lo cual el rendimiento óptimo de tareas sincrónicas es logrado al reducir al mínimo el conflicto de los recursos demandados por cada una de ellas. Estos son: las etapas de procesamiento, la modalidad y la respuesta. Las primeras se verifican en el periodo que va desde la atención temprana de un estímulo hasta su procesamiento central. La modalidad puede ser auditiva o verbal y las respuestas pueden ser espaciales (reacciones motoras) o verbales. Como se verá mas adelante, diferentes tipos de tareas secundarias llevadas a cabo mientras se conduce (tarea principal) pueden poseer diferentes tiempos de respuesta o generar mayor o menor número de perturbaciones en el sujeto (por ejemplo, tareas auditivas versus tareas visuales).

Algunos autores destacan la relación entre la tarea y las características del sujeto en la medida de carga mental. Según Gopher y Braune [58] la carga cognitiva, también llamada carga de trabajo, caracteriza el rendimiento de la tarea, y explicaría la falta de capacidad de los sujetos al enfrentarse a ella. Hart y Staveland [66] diferencian la carga de trabajo de las demandas de la tarea al argumentar que la carga de trabajo representa el costo que incurren los sujetos para lograr un rendimiento específico. Además, argumentan que la carga de trabajo contempla la interacción entre los requisitos de la tarea, las circunstancias en que se realiza, las habilidades y comportamientos del sujeto. De igual manera Recarte [142] argumenta que la carga cognitiva o mental es el resultado de la interacción entre las exigencias de la tarea y las características humanas, es decir, por separado ni las propiedades de la tarea ni las características del sujeto pueden explicar la carga mental.

Dado lo anterior, actualmente se consideran tres aspectos en la carga de trabajo [12]: la demanda de las tareas, es decir, la complejidad de las tareas para una capacidad humana limitada; el rendimiento de la tarea principal o de la tarea secundaria; y el esfuerzo, es decir, la estrategia y la asignación consciente de recursos de procesamiento mental.

#### **2.4.2. Efectos en la conducción**

Según el modelo de Wickens (véase 2.4.1) el conductor posee una cantidad de recursos limitados que debe asignar a la tarea principal (conducción), junto a otras tareas secundarias que pueden ocurrir durante la ruta. Por lo tanto, una mala distribución de recursos puede ocasionar una reducción del rendimiento de la tarea principal, lo cual favorece las probabilidades de accidentes.

Para ser más específicos, existe un concepto denominado **inatención** el cual se define como un amplio conjunto de situaciones en la cual el conductor falla en atender las demandas específicas de la tarea principal de conducción, por ejemplo, debido a la somnolencia. Cuando esto ocurre por una tarea específica (tal como atender el celular mientras se conduce), se habla del concepto de **distracción** [95].

Según [163] la distracción del conductor puede ser de tres tipos, dependiendo de su fuente y demanda: visual, manual y cognitiva. Por otro lado, la distracción se puede dividir en dos categorías: la distracción exógena, producida por objetos o eventos externos irrelevante para la conducción, o la distracción endógena, inducida por los propios pensamientos del conductor o la actividad cognitiva no relacionada con la tarea de conducir [140]. Dichas distracciones se relacionarían a una sobrecarga mental de los conductores.

Existen diferentes fuentes de distracción al interior del vehículo. Hoy en día, la mayoría de los automóviles integran nuevos sistemas de navegación o de asistencia a los conductores. Estos sistemas buscan hacer de la conducción un proceso más simple, sin embargo, muchas veces pueden provocar una carga cognitiva extra, ya que los conductores no solamente deben enfocarse en los obstáculos del camino, sino también en los mismos aparatos que utilizan para simplificar sus viajes. De hecho, tal como se menciona en [69], crear una tarea

de conducción totalmente automatizada genera una mayor carga de trabajo y estrés, porque el conductor necesita supervisar la interfaz hombre-máquina monitoreando el estado del automóvil en relación con su entorno. Por lo tanto, el conductor de estos vehículos requiere realizar la tarea de estar atento a reclamar el control en caso de ser necesario.

Un ejemplo de lo anterior es lo reportado en [3], donde investigan el efecto del uso de control de cruceo adaptativo (ACC) en la carga mental de los conductores. La carga mental se califica según el test NASA-TLX, junto con un modelo de clasificación basado en señales de EEG. Se realizan dos sesiones del circuito, donde se permite la activación y desactivación del sistema ACC a partir de la integración de un vehículo en el tráfico, lo que provoca un evento crítico de frenado. Los resultados muestran que el control de cruceo adaptativo causa distracción en un primer escenario, por lo que los conductores muestran un tiempo de respuesta más largo y una mayor carga de trabajo. En otro escenario, cada sujeto sabía que no podía confiar en el sistema, por lo que tendían a mantener un control completo del vehículo y prestaban más atención en la zona de conducción, con la consiguiente disminución de tiempo de percepción-reacción.

En [84] investigan los efectos en la carga cognitiva de conocer la capacidad de un sistema automático al momento de conducir. Para ellos ocupan 2 grupos de conductores. El primero posee un sistema de menor automatización. Cuando ninguno de los dos grupos conoce los reales efectos del sistema, ambos se encuentran atentos a la ruta. Sin embargo, al informar lo que realmente puede hacer la automatización, el grupo que posee un peor sistema tiende a tener una carga cognitiva mayor debido a que tiene que poner más atención a la toma de control.

Lo anterior demuestra los puntos dañinos de la automatización. Sin embargo, no solamente los vehículos autónomos presentan este tipo de tareas secundarias. Dentro de los vehículos tradicionales existen distracciones y tareas secundarias como son el conversar con otra persona mientras se conduce, atender el teléfono celular, cambiar la sintonía de la radio, modificar los espejos, entre muchos otros.

Es interesante notar que, dependiendo explícitamente del tipo de tarea secundaria, la carga cognitiva puede aumentar en mayor o menor proporción. Por ejemplo, en [30] se realiza un estudio comparativo entre el utilizar mapas en 2D, en 3D y en papel. Concluyen que es menos invasivo en cuanto al aumento de carga mental, el uso de mapas en 2D, aunque el mapa en 3D puede entregar mayor información, en general estos últimos involucran una carga cognitiva que no es útil al momento de conducir. De igual manera, existen estudios que hacen diferencia entre los estímulos auditivos de escuchar y hablar [29], donde los últimos pueden entregar una mayor carga cognitiva. En [83] evalúan una interfaz social que consiste en tres robot que ayudan al conductor a navegar, considerándolo como un espectador en la conversación entre agentes. Los resultados mostraron que el sistema produce una reducción de ciertos factores de carga de trabajo que ayudan al conductor a aumentar la atención en la carretera, en comparación con la comunicación uno a uno de los sistemas de navegación tradicionales.

En algunas ocasiones la tarea secundaria no se ve a simple vista. La carga cognitiva del conductor puede aumentar por condiciones de tráfico, eventos inesperados u otro tipo de características exógenas. Por ejemplo, en [22] observan que los límites de velocidad provocan que los conductores destinen mayores recursos a mantenerse dentro de los límites legales, generando una sobrecarga cognitiva. Las distracciones ocurridas en la ruta comúnmente generan un aumento en la carga mental. Sin embargo, también existe un porcentaje de carga mental inducida por la tarea principal de conducción. En definitiva, lo que se busca es no sobrepasar los niveles peligrosos.

Por lo tanto, la carga mental **no siempre posee un efecto negativo** sobre la conducción. Una baja carga cognitiva conlleva al aburrimiento del conductor y, por lo tanto, una inatención de la ruta. Por otro lado, una carga cognitiva alta lleva a una sobrecarga, en la cual las habilidades del conductor se ven sobrepasadas por las características de la conducción. En ambos casos el conductor se ve involucrado en una situación de riesgo. Por lo tanto, se busca nivel de carga cognitiva lo suficientemente alta para mantener la concentración, pero suficientemente baja como para que no se superen los recursos mentales del conductor.

### **2.4.3. Métodos de estimación de la carga cognitiva**

Uno de los principales problemas en la detección de carga cognitiva es que no hay un método directo de medición. De esta manera, no existe un instrumento que pueda medir con precisión este indicador durante la ruta. Para hacer frente a este problema y poder estudiar este indicador, se induce carga cognitiva mediante diferentes métodos experimentales y/o tareas secundarias y, a partir de ciertas características relevantes, se observan las diferencias en los momentos en que se ejecuta la actividad con inducción versus los momentos base. En la literatura existen diferentes métodos para estimar la carga mental. Entre ellas están las medidas psicofisiológicas, las de medidas de rendimiento a partir del vehículo, y las medidas subjetivas auto reportada por los conductores (véase 2.2). Diferentes medidas son sensibles a distintas características de la carga de trabajo y no todas evalúen los mismos aspectos.

Las medidas de auto-reporte corresponden a cuando los conductores declaren su situación, generalmente a partir de encuestas. De esta manera, se puede ver las diferencias en ciertas medidas en los momentos en que el conductor se identifica como cognitivamente cargado, versus los momentos base. Esta alternativa es útil en los casos donde se aplican tareas secundarias o incluso cuando no se realizan inducciones de carga cognitiva, ya que se puede conocer los diferentes niveles que aparecen debido a los eventos propios de la conducción tales como el tráfico o situaciones de peligro.

Un método de auto reporte ampliamente usado es el denominado Nasa Task Load Index (NASA-TLX) [65] utilizado en [2, 30, 42, 49, 85, 97, 131]. Esta encuesta se realiza después de cada sección experimental, evaluando escalas de valores para diferentes tópicos: demanda mental, demanda física, demanda temporal, esfuerzo, nivel de frustración y desempeño. La respuesta a cada una de estas preguntas entregan puntajes para la ponderación de un índice final. El NASA-TLX es útil para asegurar que los métodos de inducción de carga cognitiva tienen efecto subjetivo en cada conductor.

La carga cognitiva inducida por tareas secundarias no solamente se puede medir con tareas reales, sino que muchas veces utilizan tareas secundarias sustitutivas, es decir, tareas artificiales creadas para la evaluación pertinente.

Estas son ventajosas en la aplicación estándar y tienen fácil repetitividad [184]. A continuación se explican las más utilizadas.

### **Tareas secundarias sustitutivas**

**N-back:** Existen varios estudios en los cuales se utiliza el denominado N-back [61, 63, 97, 128, 158-160, 189]. Este corresponde a una tarea sustitutiva [120], en la cual el usuario escucha una serie de números con una frecuencia específica y debe recordar el N-ésimo elemento anterior de la secuencia. A medida que N se hace más grande, la tarea se hace más compleja y, por lo tanto, mayor es la carga cognitiva. El caso 0-back corresponde a repetir los números a medida que son escuchados. El caso 1-back corresponde a que cada vez que se escucha un nuevo número, se debe decir el número anterior. En general, en ambiente de conducción lo más complejo es usar un 3-back, en el cual cada vez que se escucha un nuevo número se debe repetir el elemento ocurrido en tres espacios anteriores. Aumentar la complejidad puede ser riesgoso en ambientes reales y no se han encontrado buenos resultados en ambientes de simulación.

**MAT:** Algunos estudios reportan el uso de la tarea MAT [107, 108]. Ésta es similar al N-back, ya que también corresponde a una tarea auditiva secuencial. Aquí los conductores reciben una serie de números y deben entregar la suma de los dos últimos. Al escenario donde los números presentan un solo dígito se le denomina MAT-1. El caso MAT-2 corresponde a secuencias de números de dos dígitos.

**Otras tareas secundarias:** En algunos estudios se busca medir el efecto de cierta actividad secundaria como son el contestar llamadas telefónicas, o cambiar el volumen de la radio [85, 192]. Estas tareas sustitutivas corresponden a tareas reales. En otros casos, se busca medir dichos efectos a partir de tareas sustitutivas que finalmente dependen de los objetivos de cada investigación. Por ejemplo, para medir los efectos de instrucciones auditivas dada por un asistente de conducción, se puede generar tareas sustitutivas de audios. En ciertas ocasiones se reportan nuevas tareas secundarias como por ejemplo en [184], donde reportan la tarea de detección de colores, que corresponde a una tarea visual en la que el usuario debe identificar el cuadrante con color diferente.

## **Conducción con tareas secundarias de rendimiento**

Como se mencionó anteriormente, la conducción se puede llevar a cabo en un ambiente real de ejecución, o en un ambiente simulado. Algunos estudios especifican rutas, tanto urbanas como de carretera, donde los conductores deben seguir un camino establecido. Hay casos donde la conducción se hace de manera normal, mientras se aplica una tarea secundaria sustitutiva para inducir carga cognitiva. En otros casos no se induce carga cognitiva con tareas secundarias, evidenciando la carga de cada sujeto a partir de medidas de auto reporte.

Por otro lado, es posible evaluar la carga cognitiva y sus efectos en características psicofisiológicas que presenten cambios en los momentos de mayor carga, respecto a lo momentos base. También se pueden usar características de rendimiento generalmente relacionadas con mediciones del vehículo. La desventaja es que estas características pueden verse afectados por condiciones de tráfico. Por ejemplo, en estos casos se pueden usar características como ángulo de desviación del volante, cantidad de frenado o velocidad del vehículo, los cuales se ven fuertemente influenciados por la calidad de la carretera, el tráfico, las condiciones climáticas, entre otros factores. Para evitar esto, en algunos casos se entregan instrucciones en la prueba que permitan controlar los rangos de movimiento y el ruido en las señales. La desventaja es que esto aumenta el riesgo y en general deben llevarse a cabo en ambientes de simulación.

A continuación, se muestran algunos ejemplos en los que se especifican instrucciones en la conducción permitiendo medir el rendimiento de manera más detallada (evitando condiciones exógenas) y cómo es afectado debido a los niveles de carga mental de cada sujeto:

**Seguimiento de un vehículo líder:** Existen estudios en los cuales se ha reportado que la tarea principal de conducción se basa en el seguimiento de un vehículo líder. En algunos casos, este vehículo puede crear situaciones de frenado repentino [53, 108]. En otros casos, se generan eventos tales como la disminución de velocidad o la aceleración. Se puede considerar que estos eventos involucran una carga cognitiva mayor al momento de conducir. Se pueden aplicar tarea secundaria al mismo tiempo que se hace la tarea de seguimiento, como por ejemplo en [99] donde se aplica una tarea de distracción auditiva; en [107]

donde se aplica una tarea MAT o en [49] donde se realizan tareas de manejo de IVIS (*in-vehicle information system*). En otros casos, se puede combinar con tareas propias de la ruta tales como evadir peatones o adelantar vehículos [42]. La desventaja de este enfoque es que resulta ser demasiado peligroso para realizarlo en un ambiente de conducción real, realizándose generalmente en ambiente de simulación. Una ventaja es que aquí, se pueden considerar métricas de rendimiento como la distancia al vehículo líder o el tiempo de reacción como medida de los cambios en la carga cognitiva del sujeto.

**Cambio de carril durante la conducción:** Durante el trayecto se le pide al conductor que realice cambios de carril en función de señales. En [199] una señal visual indica el momento en que se deben realizar los cambios. Así, la métrica de rendimiento puede ser la desviación media del centro del carril.

**Detección de eventos en el camino:** Durante el trayecto se le pide al conductor que identifique ciertas señales ocurridas durante la ruta. Por ejemplo, en [69] se les pide a los conductores que identifiquen cada vez que pasan por un puente. La métrica de rendimiento puede ser la cantidad de eventos detectados, o la tasa fallas en la detección. En [191] se les pide a los conductores que reconozcan ciertas señales e identifiquen la dirección correcta de destino.

#### 2.4.4. Análisis de la literatura

En la sección 2.4.3 se explican los tres métodos para estimar carga cognitiva: el auto reporte, el uso de medidas psicofisiológicas y las medidas de rendimiento. A continuación se present estudios para las dos últimas categorías.

En algunas investigaciones, se combinan características de tipo psicofisiológico y de rendimiento. Por ejemplo, en [193], muestran buenos resultados en un modelo de clasificación, utilizando tanto datos del vehículo como la velocidad y aceleración, como datos psicofisiológicos del participante, como son el ritmo cardiaco (HR) y su variabilidad (HRV), la temperatura de la mano y el SCR. En [42] utilizan el ECG, el EDA y características del vehículo como la posición y la velocidad longitudinal del vehículo. Mediante un análisis estadístico ANOVA concluyen que la utilización de la combinación de medidas electrofisiológica y conductuales puede ser útil para mejorar la estimación de carga de trabajo mental.

En [192] realizan un modelo utilizando medidas del vehículo como la velocidad y aceleración lateral, además de datos psicofisiológicos como ECG, HR, HRV, BR, GSR. Utilizando una red convolucional, son capaces de agrupar la información de cada una de estas señales encontrando modelos poblacionales e individuales, con transferencia de aprendizaje desde el primer caso hacia el segundo.

En [160] realizan un clasificador de niveles de carga cognitiva utilizando algoritmos de Support Vector Machine (SVM) para la carga mental. Utilizan medidas de rendimiento del vehículo tales como la distancia, velocidad, dirección, aceleración y frenado, y medidas fisiológicas como el seguimiento ocular y el HR calculado a partir del ECG. Concluyen que el modelo para los conductores jóvenes mejora en el dominio de rendimiento de la conducción, sin embargo, no así al utilizar características psicofisiológicas. Por lo tanto, recomiendan utilizar medida de dominio cruzado (rendimiento del vehículo y psicofisiológicos) para mejorar la solidez general de los modelos frente a factores de la edad.

Respecto a lo anterior, la edad del conductor influye en el aumento de la carga cognitiva. En [85] estudian este efecto, relacionada con 5 tareas de conducción. Encuentran que los conductores mayores muestran diferencia estadísticamente significativa en las puntuaciones NASA-TLX, en el tiempo para completar las tareas y tienden a presentar mayor distracción cuando realizan tareas relativamente complicadas.

Otros estudios también consideran la comparación entre medidas de rendimiento y medidas psicofisiológicas. En [198] utilizan medidas psicofisiológicas y del vehículo para clasificar la carga cognitiva. Utilizan un modelo de regresión múltiple pero utilizando conglomerados. Los resultados comparativos con el sistema de promedio convencional demuestra que el enfoque propuesto mejora significativamente el rendimiento de la predicción de carga de trabajo.

En [56] realizan un modelo basado en random forest y SVM utilizando tanto datos psicofisiológicos, como del vehículo. Aquí muestran que los resultados de los modelos individuales y modelo grupales funcionaron bien en un entorno de conducción realista al generalizar en conductores desconocidos sobre el estudio de mantenimiento de carril. También se concluye que el modelo a nivel de grupo no resulta ser tan bueno como los modelos a nivel individual.

## **Estudios basados en mediciones del vehículo**

Como se mencionó anteriormente, algunos estudios miden la carga cognitiva y cómo afecta a características propias del vehículo, tales como la velocidad, la aceleración, los desplazamientos laterales y el frenado. Esta es una manera de medir las respuestas involuntarias de los conductores ante un aumento de la carga cognitiva. Además, se observa que no solamente existen cambios involuntarios como disminuir los desplazamientos laterales del vehículo, sino también acciones compensatorias para lograr un mejor rendimiento en tareas secundarias y conducción al mismo tiempo. Sin embargo, como se a mostrado anteriormente, medir la carga cognitiva directamente a partir de estas características puede sufrir del ruido provocado por efectos propios del tráfico, eventos inesperados o condiciones de la carretera.

Respecto a los movimientos involuntarios, se han hecho estudios para demostrar que estos corresponden a efectos de la carga mental y no de otros factores. En [37] realizan un experimento para determinar si la carga cognitiva disminuye el desplazamiento de la posición lateral del vehículo y si esto es independiente de la actividad ocular. Aquí, la métrica de rendimiento corresponde a la desviación del carril. Los resultados indicaron que el movimiento oculares desempeñan un papel modesto en la variabilidad de la posición lateral mientras que la carga de trabajo cognitivo desempeña un papel mucho más sustancial. Este es un ejemplo de movimiento involuntario.

Como se mencionó en la sección 2.4.1, la carga cognitiva no depende de la tarea o del participante de manera independiente. En [131], 20 conductores tuvieron que recorrer una ruta de tres secciones de autopista, carretera rural y ciudad. Durante el trayecto se medía la carga cognitiva mediante el test NASA-TLX y el cuestionario RMSE. Usando un clasificador, concluyen que la características que influyen fuertemente en la carga cognitiva son: la situación de conducción, el género y la frecuencia de conducción.

En [11] utilizan datos de velocidad, posición en el carril y del volante, en conjunto con patrones de la mirada del conductor para evaluar diferencias significativas al realizar distintos experimentos en un ambiente de simulación y en ambientes reales. Las tareas secundaria consistían en 7 tareas vocales auditivas y 7

tareas manuales visuales. Encuentran diferencias significativas al conducir en un ambiente real y en un ambiente de simulación. Además, existen diferencias basadas en el género y en la edad. Por otro lado, existen diferencias altamente significativas en la carga de trabajo según el tipo de tarea secundaria que se realiza en cada prueba.

En [159] realizan un estudio para ver cómo la carga cognitiva puede afectar la conducción de manera diferente para conductores de menor o de mayor edad. Mientras conducen, realizan una tarea secundaria de n-back para la distracción auditiva. Las características consideradas son la distancia de conducción, velocidad, dirección, aceleración y frenado. Los resultados indicaron que el entorno del tráfico influye tanto en el rendimiento de la conducción como en el comportamiento compensatorio de manera diferente para los grupos etarios. La tasa de errores de la tarea n-back fue mayor para el grupo mayor edad. Al mismo tiempo el grupo de mayor edad condujo más lento que el grupo joven y este último mostró una capacidad de control de velocidad constante independiente del entorno de tráfico.

En [191] se evalúan los efectos del radio horizontal, la inclinación de la pendiente, el flujo de tráfico y la información de las señales presentadas en las rutas, en la carga de trabajo y el rendimiento percibido de la conducción. En este caso el rendimiento de la conducción se indica mediante el control de la velocidad y la capacidad de mantener el carril. Mediante un análisis de hipótesis ANOVA se concluye que el puntaje de demanda mental y física aumenta en las curvas. Además, la carga de trabajo subjetiva aumenta junto con la información en las señales. Respecto a medidas compensatorias, también se observa la reducción de velocidad de conducción para lograr un mejor rendimiento.

En [12] utilizan la duración del uso de los frenos y la duración de la presión de los pedales de aceleración como indicadores. Además, evalúan características de la posición de la mirada en áreas de interés. En una ruta donde los participantes debían hacer giros a la derecha y a la izquierda descubrieron que las características de conducción se relacionan con características propias del sujeto como la inadaptación situacional, la personalidad de toma de riesgo y la inadaptación interpersonal medidos a través de una encuesta.

En [102] los participantes debían conducir en un ambiente de simulación a una velocidad de 65 mph (unos 105 km/h). Cuando conducía muy lento los vehículos de atrás tocaban la bocina y cuando conducían muy rápido, sonaba una alarma. La carga cognitiva en este caso corresponde a mantener una velocidad constante y se auto reporta por los participantes. Realizaron diferentes escenarios: sin tráfico, 5 niveles de distancia de frenado y agregando vehículos selectivamente. Los resultados indican que la carga de trabajo disminuye con el aumento de la distancia de frenado. Además, el aumento del avance de los vehículos circundantes disminuye la carga de trabajo y la contribución de los avances se vuelve cada vez más pequeña.

Por lo tanto, algunas conclusiones importantes son que el aumento de la carga cognitiva puede verse reflejado en las métricas calculadas desde sensores del vehículo, pero los resultados dependen de características propias del usuario como el género y la edad, tanto en sus movimientos voluntarios como involuntarios. Además, dependiendo de la tarea secundaria que se desarrolle, existirán comportamientos compensatorios para mantener un buen rendimiento tanto en la conducción como en el desarrollo de la actividad secundaria. De esta forma, utilizar métricas de rendimiento para la evaluación de la carga cognitiva debe considerar dichos factores.

En cuanto a la regulación de la carga cognitiva basada en mediciones a partir de características de rendimiento, es importante considerar que aunque lo que se desea es la disminución de carga cognitiva en los casos de mayor peligro, se observa que ésta no se reduce inmediatamente. En [123] utilizan un sistema de navegación que presenta fallas durante la conducción para evaluar cómo afecta la carga cognitiva a través del tiempo. En este caso utilizaron el método estadístico ANOVA para demostrar las diferencias significativas existentes en características de velocidad del vehículo, el diferencial de velocidad, el accionamiento del acelerador y el accionamiento del freno. Llegaron a la conclusión de que existe un efecto de histéresis en la carga cognitiva presentada en la conducción. Esto quiere decir que durante los ensayos se produjo una reducción gradual de la carga mental y una recuperación retardada hasta la reducción de la demanda de tareas.

## **Estudios basados en medidas psicofisiológicas**

Respecto a los estudios relacionados a la medición de la carga cognitiva a partir de señales psicofisiológicas, se encuentran métodos estadísticos, pruebas de hipótesis y/o clasificadores basados en técnicas de Machine learning. Las señales utilizadas en los estudios encontrados corresponden a pletismografía, Electrocardiograma (ECG), Respuesta galvánica de la piel (GSR), Electroencefalograma (EEG), Electrooculograma (EOG), Electromiograma (EMG), dilatación pupilar, Funcional near-infrared spectroscopy (fNIRs), respiración y pulso sanguíneo (Ver sección 2.2.1).

De las señales anteriores se calculan algunas características importantes para la evaluación. Por ejemplo, muchas veces se utiliza el electrocardiograma para obtener el ritmo cardíaco (HR). También se calculan las medidas la variación de ritmo cardíaco (HRV), la componente de baja frecuencia (LF) y la componente de alta frecuencia (HF).

Se pueden combinar diferentes señales psicofisiológicas para una medición más detallada de la carga cognitiva del conductor. Por ejemplo, en [96] desarrollan un experimento de conducción, en el cual los conductores deben realizar una tarea secundaria de conteo en retroceso desde un número aleatorio entre 60 y 100. Utilizan datos de ECG, un cinturón de respiración, movimientos oculares y movimientos de la cabeza. Los test estadísticos desarrollados sugieren que la carga de trabajo del conductor depende de la ubicación del vehículo (medida por GPS), ya que los valores de Rating Scale Mental Effort (RMSE) fueron altos en algunos lugares específicos de la ruta. Respecto a las señales psicofisiológicas se observan que el porcentaje de la mirada dirigida al centro de la carretera tiende a aumentar con el incremento de la velocidad de conducción y la frecuencia cardíaca aumenta al realizarse la tarea secundaria.

A continuación, se muestran los estudios correspondientes a cada señal psicofisiológica y sus principales conclusiones.

### **Pletismografía:**

El pletismograma es un dispositivo para medir los cambios en el volumen de la sangre, o el aire que contiene dentro de un órgano o todo el cuerpo. Uno de los

métodos para analizar la onda de pulso sanguíneo del pletismograma es usando el máximo exponente de Lyapunov. Este es un parámetro que mide la inestabilidad orbital de la muestra de datos.

En [107] utilizan un método de ANOVA para detectar cambios en el exponente de Lyapunov. En un simulador los participantes debían seguir un automóvil líder y al mismo tiempo completar tareas secundarias de MAT. Demuestran que procesando la señal pueden obtener diferencias en el momento de mayor carga cognitiva reflejado en un mayor exponente de Lyapunov. En [108] refuerzan lo encontrado en el estudio anterior, replicando el experimento y demostrando que el exponente de Lyapunov puede ser utilizado para la detección incluso sin la necesidad de normalizar la señal.

### **Electroencefalograma:**

Existen diferentes estudios relacionados a la detección de carga cognitiva a partir de las señales de EEG. La mayoría utilizan características extraídas de forma manual, tanto en el dominio del tiempo como en el de la frecuencia. Sin embargo, en [75] demuestran que estas señales en sus bandas de frecuencia alpha y theta pueden ser utilizadas extrayendo características de manera automática. A diferencia de otros estudios, se entrenan clasificadores basados en deep learning para detectar los niveles de carga cognitiva en función de características extraídas por un auto encoder, compuesto de redes neuronales convolucionales.

En [2] también se ha demostrado que la carga cognitiva posee efectos en las bandas alpha y theta en la complejidad de la conducción luego de utilizar el EEG para la clasificación de carga cognitiva entre las situaciones de conducción simple, compleja y muy compleja.

En [97] demuestran la importancia de estas bandas al realizan un experimento de cambio de carril con tareas secundaria de n-back mientras se conduce. Utilizan características de potencia frontal theta y potencia parietal alfa de los participantes, medido a partir del EEG. Los resultados indican que el aumento de carga en la memoria trabajo indujo un aumento en la potencia theta y una disminución de la potencia alfa, y un aumento de las cargas del área de conducción indujo a una disminución de la potencia alfa.

Esta señal puede ser complementada con otras, como es, por ejemplo, el caso realizado en [49], donde utilizan tanto la señal de EEG como ECG. Para la primera calculan la actividad de fondo y el ratio entre la banda beta y alfa.

### **Respuesta galvánica de la piel:**

En [158] desarrollan una regresión logística para clasificar momento de carga cognitiva inducida por una tarea secundaria de n-back. Combinan la señal ECG y la señal EDA. Demuestran buenos resultados con la utilización de la media, la desviación estándar, el mínimo, el máximo y la primera derivada del nivel de conductividad de la piel (SCL).

Existe debate acerca de la utilidad de esta señal en la medición de la carga cognitiva en los ambientes reales. En [152] realizan un estudio que busca conocer las actividades más demandantes en la conducción. Utilizan datos de actividad electrodérmica y dilatación pupilar. Sin embargo, concluyen en base a los resultados en el estudio en tráfico real que la medida de actividad electrodérmica no proporciona suficiente sensibilidad para la carga de trabajo durante las tareas rutinarias. Por otro lado, en [60] realizan un experimento en una ruta de ambiente real, con curvas a la izquierda y a la derecha. Durante el trayecto miden el ECG y el EDA. Observan que en la maniobra de giro la señal obtenida del EDA muestra un cambio más significativo, en relación con las variables obtenidas del ECG, para la descripción de la carga mental del conductor. Por lo tanto, concluyen que el EDA es más adecuado para reflejar la carga de trabajo del conductor. Sin embargo, los análisis realizados corresponden a estadística básica, y no reportan la significancia de los resultados.

### **Electrocardiograma:**

Las características más comunes para el uso del ECG en la detección de carga cognitiva son el ritmo cardiaco (HR), su variabilidad (HRV), y sus componentes de baja frecuencia (LF), y alta frecuencia (HF) y el ratio LF/HF. Estos son utilizados en [30], para concluir los efectos en la carga cognitiva del conductor que provocan los diferentes tipos de mapa de navegación (3D, 2D o en papel).

En [174] buscan establecer una relación entre la carga cognitiva y la fatiga de los conductores respondiendo a la interrogante: ¿qué medida cardiovascular es

más sensible a la discriminación entre carga cognitiva y/o fatiga entre las tareas?. Para ello calculan HR y HRV. Además, calculan la baja frecuencia LF, la muy baja frecuencia VLF y la alta frecuencia HF.

En [74] evalúan el piloto automático de los automóviles Tesla. Calculan el HR y la relación LF/HF. Con dichas características concluyen que la carga cognitiva es baja y disminuye a través del tiempo de adaptación de los pilotos a esta tecnología, lo cual no necesariamente correspondería a algo deseable.

En [48] analizan la correlación entre las variables del ritmo cardíaco, calculadas a partir del ECG en un ambiente simulado de conducción en la carretera. Encuentran que los parámetros de HRV, la baja frecuencia del espectro de frecuencia y del espectro de frecuencia parametrizado, sirven como potenciales indicadores de la carga de trabajo subjetiva.

### **Respiración:**

En [61] además de utilizar el EDA y el ECG agregan un cinturón de respiración. Con este sensor calculan la frecuencia respiratoria como medición para la carga cognitiva. La carga de trabajo secundaria consiste en periodos de 2 minutos de la tarea de 2-back. Identifican correctamente los periodos de alta carga de trabajo en el 83 % de todos los casos para 18 sujetos. Para ello ocupan un árbol de decisión. Además, plantean una contramedida basada en un adaptador de velocidad crucero que contiene información de la carga cognitiva del conductor, permitiendo un control suficiente como para evitar los periodos de aburrimiento y de alta carga cognitiva.

### **Movimiento ocular y dilatación pupilar:**

Características relacionadas al movimiento ocular han sido ampliamente utilizadas en la literatura para la detección de carga cognitiva. En [99] realizan un experimento de seguimiento de un vehículo líder. Mientras los conductores manejan también tienen que realizar una tarea secundaria auditiva que corresponde a escuchar instrucciones de tres palabras y dos precios, los cuales deben recordar y comparar con precios posteriores. En este estudio utilizan características tanto del vehículo, como del sujeto. Respecto a las medidas psicofisiológicas utilizan movimiento ocular, particularmente la frecuencia de

parpadeo, la duración y dirección de la fijación, la distancia, dirección y velocidad de la mirada. Además, utilizan características del vehículo de ángulo del volante, posición del carril y error de dirección. Los resultados muestran que las características temporales del movimiento ocular son los indicadores más predictivos de la distracción cognitiva, seguidos por las características espaciales del movimiento ocular.

En [128] realizan un experimento en simulador en el cual conducen y realizar una tarea secundaria de n-back. Correlacionan variables oculares como la tasa de parpadeo, el cambio en el tamaño del diámetro de la pupila, la duración de fijación y cambio de ubicaciones de fijación del eje vertical y horizontal durante los periodos de desarrollo de la tarea secundaria y los periodos normales de conducción. Los resultados muestran que el cambio medio del diámetro de la pupila parece ser la medida más sensible a la carga de trabajo cognitivo. Por otro lado, los parpadeos parecen ser una medida altamente dependiente de la naturaleza los recursos atención requeridos por la tarea secundaria mientras se conduce.

El uso de estas señales puede presentar ventajas en relación a otras. Por ejemplo, en [53] argumentan que el número de participante necesarios para detectar la carga de trabajo es menor al utilizar la dilatación pupilar en relación al uso del HR, debido a la existencia de casos de alta carga cognitiva no detectados por esta última señal al realizan una tarea de n-back mientras conducen.

Muchas veces la detección de la actividad ocular se lleva a cabo mediante cámaras que registran la cara de los conductores. Por ello, se pueden complementar con otras métricas relacionadas a movimientos corporales. Por ejemplo, en [196] utilizan el movimiento ocular y la posición de la cabeza para detectar la carga cognitiva. En particular, la frecuencia de parpadeo, el porcentaje de cierre del ojo y el ángulo de inclinación para la mirada de cada ojo. En este caso diferencian entre tareas secundarias que inducen carga mental y carga visual. Para el primer caso obtuvieron un clasificador con 76 % de precisión y en el segundo uno con 91 % de precisión.

En [63] realizan una simulación de la mirada mediante el modelo de reflejo vestibulo ocular (VOR) y el modelo de reflejo optocinético (OKR). Estos modelos

presentan errores. Dichos errores fueron medidos en los casos con carga y sin carga mental. Concluyen que las personas mayores muestran un peor rendimiento que los jóvenes bajo conducción distraída.

En [100] realizan un experimento simulado en el cual consideran características de rendimiento del vehículo, pero también de la fijación de los ojos del conductor. En este experimento utilizan una tarea secundaria de reconocimiento de reloj. Aquí, se presenta en cada intersección de la ruta un aviso auditivo y se visualizan las manecillas de un reloj, al cual los conductores deben responder la hora correcta. A diferencia de muchos estudios anteriores, la tendencia de rendimiento la conducción y la fijación de ojos no está necesariamente relacionadas entre sí con el aumento de la carga mental. Según este estudio en comparación con el rendimiento de conducción altamente diversificados la carga mental se asocia más consistentemente con el cambio de la variabilidad de la fijación del ojo. En cuanto al efecto de la experiencia de conducción en respuesta al aumento de la carga mental los conductores novatos muestran una mayor variabilidad de la mirada y son más propensos a no mantener el control del vehículo que los conductores experimentados.

En [69] crean un detector de carga cognitiva a partir de videos de la cara de conductores. Utilizan multicámaras y extraen 14 características que ingresan a modelos de redes bayesianas y a un modelo de random Forest. Los resultados muestran una precisión del 95 % cuando el sistema se entrena por separado para cada sujeto y un 68 % cuando se hace a nivel poblacional, es decir, independiente del sujeto.

## **2.5. Estrés en conducción**

### **2.5.1. Definiciones**

El estrés es un fenómeno complejo que ha sido estudiado por muchos años. Se puede definir como la respuesta corporal no específica a una combinación de demandas externas e internas [153]. Existen dos conceptos para diferenciar el tipo de estrés. El estrés positivo se denomina eustrés, producido cuando la capacidad percibida del individuo supera a las demandas externas, y ayuda a aumentar la creatividad, motivación y productividad. El estrés negativo se denomina distrés, el cual nace por el desequilibrio de las capacidades del individuo para hacer frente a las demandas externas. En lo que sigue de este documento el término estrés hace referencia a la forma negativa.

El estrés es causado por un interviniente desagradable llamado estresor y se relaciona con la actividad del sistema nervioso autónomo. Además, se ve influido por los parámetros individuales del sujeto, es decir, sus preocupaciones internas.

En la conducción, el estrés puede deberse a muchos factores estresantes como: ergonomía de la cabina, ruido ambiental, fatiga, aburrimiento, enfermedades, drogas, tráfico, el clima, la conducción nocturna, problemas personales o la carga de trabajo.

Existen tres tipos de estrés. El estrés agudo, causado por un corto plazo estresante, el estrés episódico, causado por la repetición de vez en cuando de estrés agudo, y el estrés crónico, causado por eventos estresantes que duran mucho tiempo. Este último resulta perjudicial para la salud humana.

### **2.5.2. Efectos en la conducción**

La actividad de conducción es compleja y cambiante, por lo cual puede causar factores estresantes de manera repetitiva, provocando estrés agudo o episódico. Existen factores internos, tales como la experiencia del conductor pero también factores externos, como las condiciones de tráfico, que pueden provocar este fenómeno. Según [146] se pueden considerar 5 categorías para los factores estresantes a corto plazo: (1) interacciones sociales, (2) situaciones inesperadas,

(3) comportamiento de conductores o peatones, (4) eventos que afectan al horario y (5) dificultades de conducción según la planificación urbana.

La reacción al estrés se ve influida por rasgos de la personalidad tales como la agresividad y la aversión a la conducción, como también por la importancia subjetiva que se atribuye al factor estresante en un contexto determinado.

El estrés se relaciona fuertemente a los accidentes de tráfico reportados por diferentes instituciones ya que puede afectar el desempeño del conductor, causando estados emocionales negativos que pueden dañar su confianza, reducir su atención y eventualmente interrumpir su concentración, lo que lleva a acciones peligrosas como, por ejemplo, el aumento de agresividad y el peligro, y una menor atención en las situaciones de tráfico [54].

En el largo plazo, el estrés del conductor puede causar agotamiento físico, fatiga, dolor de hombro y espalda e hipertensión [13], principalmente por los factores estresantes existentes en los ambientes de conducción o las situaciones externas como las antes mencionadas.

El estrés no solo aumenta debido a una mayor carga cognitiva del sujeto sino que también puede provocar una mayor demanda cognitiva (relación bidireccional), lo que, como se vio en la sección 2.4.1, puede causar un procesamiento inadecuado de la información y distracciones cognitivas que aumentan el riesgo de sufrir accidentes.

### **2.5.3. Métodos de estimación de estrés**

Al igual que para el caso de la carga cognitiva (véase 2.4.3), no existe un método directo para la medición de estrés. Por lo tanto, la mayoría de los estudios se enfoca en la evaluación de características que presenten diferencias significativas en momentos definidos de mayor o menor estrés, generados o identificados a partir de la inducción de estresores relacionados a la ruta o eventos externos a la conducción; o bien, a partir del autorreporte entregado por los participantes. Para ello, se desarrollan clasificadores entrenados mediante metodologías de machine learning o test estadísticos que validan el uso de ciertas características representativas.

En [41, 67, 194] utilizan una escala autorreportada de los conductores para su nivel de estrés durante la conducción en cada sesión experimental. En [145] el autorreporte lo desarrollan a nivel de evento, clasificando cada situación particular en la ruta dentro de categorías de evento estresante o no estresante. En [165] utilizan la sección de frustración del test NASA-TLX (véase 2.4.3) para etiquetar los niveles de estrés de los conductores en cada sesión experimental.

Al igual que en el caso de la carga cognitiva, el método de etiquetado con autorreporte permite conocer los niveles de estrés de los conductores de una manera sencilla. Sin embargo, puede provocar interferencia en la experimentación y, además, requiere de un entendimiento de los conceptos utilizados por parte de cada sujeto.

Otra manera de conocer el nivel de estrés es mediante el análisis de registros de los conductores durante la experimentación. En [68] utilizan los audios registrados de los camioneros mientras conducen para clasificarlos según votación de 6 expertos en escalas de estrés utilizando el método SAM (Self-Assessment Manikin). En [161] utilizan los videos de los conductores para clasificar el nivel de estrés según el comportamiento registrado. Este es un método menos invasivo que el caso del autorreporte pero requiere de métodos validados de clasificación.

Durante esta revisión bibliográfica, se observan estudios realizados con conducción en ambientes reales de ejecución, como también en ambientes simulados. Este último caso permite generar un mayor número de eventos estresantes en la ruta o manejar otro tipo de estresores como lo es la condición climática.

Respecto a los métodos para inducir estrés, en muchos casos se relacionan los momentos de mayor nivel a ubicaciones específicas de la ruta. Algunos estudios consideran rutas habituales de conducción [31, 57, 67, 180, 182, 183], mientras que otros comparan entre los tramos de ciudad y carretera [18, 68, 93, 165], rutas con túneles [112, 121] o rutas de ciudad y rutas rurales [86]. En otros casos, se agregan eventos estresantes mediante eventos en el camino, propios de la ruta o mediante tareas secundarias. Para poder considerar una ruta como estresante

o no estresante, se pueden definir metodologías claras desde los criterios del experimentador o etiquetar según encuestas realizados a los mismos conductores a nivel poblacional [157].

Respecto de las tareas secundarias, se encuentran casos en los que se usan llamadas telefónicas como eventos estresores [21, 62] o sonido de llamada sin contestar [106]. Además, existen casos en los que se realizan preguntas matemáticas mientras se conduce [17, 106]. Una tarea secundaria es hacer movimientos del manubrio según el sonido de un metrónomo, el cual puede entregar sonidos imprevistos para causar el estrés deseado en el conductor [4, 202]. Aunque en la mayoría de los casos no se etiqueta directamente en función de estas tareas secundarias, existen casos como en [21], donde el estrés está dado por los momentos de desarrollo de tareas secundarias, en este caso de hablar con el copiloto.

Otra forma interesante de medir el estrés es relacionarlo con las emociones [54, 137]. Bajo este enfoque, se busca detectar aquellas emociones negativas que estén relacionadas con el estrés al conducir (generalmente enojo y disgusto) dentro de un conjunto de emociones presentes universalmente en todos los sujetos. Este es un método un tanto indirecto pero aceptado en la literatura que requiere de sistemas de detección de emociones claros, los cuales pueden estar basados en los modelos computarizados entrenados o en el juicio experto de los experimentadores.

En [137] demuestran que las emociones se relacionan con las situaciones de mayor riesgo de accidentes. Utilizando datos de EEG, ECG y EMG para modelar los estados de angustia, miedo y disgusto (emociones asociadas al estrés), autorreportado por los conductores. Observan que en el 72 % de los casos los conductores demostraron un mayor nivel de estrés al pasar por un cruce peligroso. Además, en la mayoría de los lugares marcados como peligrosos, es decir, donde se informó de choques, asaltos a peatones, ciclistas u obstáculos, los sensores indicaron una desviación del estado emocional habitual de los conductores. Por lo tanto, una desviación considerable (tanto positiva como negativa) del estado emocional habitual puede conducir potencialmente a un accidente de tráfico.

Respecto a otros métodos de estimación, se pueden encontrar alternativas basadas en la naturaleza del efecto estrés. El sistema nervioso es responsable de ejecutar una estrategia en tres pasos: sentir, percibir y responder al estrés. De esta forma, los datos acerca del ambiente y acerca del interior del sujeto son percibidos y procesados en el cerebro, el cual envía respuestas a los motores somáticos y automáticos de diferentes partes del cuerpo, creando reacciones voluntarias e involuntarias a los factores estresantes. Por lo tanto, se puede medir el estrés a partir de métricas de rendimiento relacionadas con respuestas voluntarias, o cómo se hace en la mayoría de los casos, con respuestas psicofisiológicas. Respecto a las mediciones de respuesta voluntarias se pueden encontrar medición de expresiones faciales, vocalización y datos dinámicos del vehículo como lo son la velocidad aceleración y frenado. Respecto a las respuestas involuntarias, se ha concluido que el nivel de adrenalina y cortisol en varios fluidos corporales presentan cambios al momento de situaciones estresantes. Además, se ha medido el estrés mediante la actividad cardíaca, actividad electrodérmica, actividad respiratoria, temperatura de la piel y dilatación de las pupilas.

#### **2.5.4. Análisis de la literatura**

En la sección 2.5.3 se explican los métodos de medición del estrés: el auto reporte, el uso de medidas psicofisiológicas y el rendimiento. A continuación, se analizan estudios para las últimas dos categorías, puesto que un sistema basado en el auto-reporte no tiene sentido real para la disminución de accidentes, además de ser un método sumamente invasivo en la tarea principal de conducción.

En algunos estudios combinan el uso de señales psicofisiológicas junto a medidas de rendimiento. En [94] utilizan un wearable tipo guante con sensor PPG en el dedo para capturar las señales de HR y HRV junto con sensor de movimiento triaxial para medir el movimiento del volante y clasificar estados de estrés y no estrés inducidos por distintos escenarios en simulador y distintos tipos de maniobras. Se alcanza un 95 % de precisión utilizando un modelo de clasificación SVM. Algo similar realizan en [93] utilizando un guante tipo wearable pero utilizando los movimientos del volante y las señales de EDA para la clasificación, alcanzando un 94.68 % de precisión.

En [121] se registran datos de ECG y frecuencia cardiaca, además de medidas de rendimiento de conducción como la velocidad del vehículo y el frenado. Se utilizaron los análisis multivariantes y univariantes de la varianza para identificar los aumentos del estrés de los conductores durante varios segmentos de la carretera: la transición a la entrada de un túnel, dentro de un túnel, y los segmentos de carretera abiertos. Las mayores variaciones en las medidas de rendimiento se observaron en los túneles, seguidas de los períodos en los segmentos de transición.

En [86] estudian el estrés en los conductores de vehículos eléctricos. Obtuvieron datos psicofisiológicos de electroencefalograma (EEG) y la observación de los ojos, junto con datos de funcionamiento del vehículo, como el estado de carga, la altitud y la velocidad. Proponen un marco teórico para evaluar la información mutua entre los datos psicofisiológicos y operacionales, así como la entropía de los propios datos psicofisiológicos, encontrando dos grupos de sujetos, uno que no muestra mucha evidencia de estrés y el otro que muestra suficiente estrés.

Existen algunos estudios que han desarrollado detectores de estrés en base a medidas conductuales adquiridas por sensores que no corresponden a la categoría psicofisiológica ni por rendimiento. En [180] utilizan datos obtenidos mediante un smartphone de la vista de la pista de conducción y desarrollan un predictor de estrés en base al comportamiento de conducción y a las maniobras peligrosas que realiza el sujeto. En [57] estudian la conducción en ambiente real y utilizan los registros de audio de voz para calcular características en el dominio de la frecuencia y espectral para desarrollar un clasificador basado en SVM el cual logra un error cuadrático medio de 1.5, de las 3 categorías de estrés definidas según las dimensiones emocionales de valencia y excitación.

### **Estudios basados en mediciones del vehículo**

A diferencia de los estudios sobre carga cognitiva, para el estrés son menos utilizadas las métricas obtenidas del vehículo, sin embargo, se pueden encontrar algunos ejemplos. En [121] concluyen la existencia de un efecto en el comportamiento de los conductores al momento de enfrentar un túnel, ya sea entrando, saliendo o dentro de estos. Dichos cambios se reflejan en la disminución

de velocidad al entrar, el aumento al salir, y los cambios en el ritmo cardiaco. Las métricas utilizadas son las medias y desviaciones estándar de velocidad y desaceleración calculadas para cada participante.

En [21] proponen la utilización de datos de velocidad del vehículo, ángulo del volante y sensores de presión del pedal del acelerador/freno. Con esto construyen un detector de distracción basado en momentos de ejecución de una tarea secundaria de habla, con una precisión de 98 %. Demuestran así la relevancia de métricas útiles para la detección: componentes de alta frecuencia, descomposición de ondas, entropía de muestra y desviación estándar aplicados sobre el ángulo del volante y los canales de velocidad.

En [93] demuestran que los movimientos del volante pueden ser medidos a partir de datos obtenidos por un sensor IMU ubicado en un wearable tipo guante, el cual posee giroscopio, magnetómetro y acelerómetro, y de esta manera logran clasificar los momentos de estrés con un 94,68 % de precisión observando sólo el movimiento de la mano del conductor mientras manipula el volante.

### **Estudios basados en medidas psicofisiológicas**

Respecto a los estudios relacionados a la medición del estrés a partir de señales psicofisiológicas, se encuentran métodos estadísticos, pruebas de hipótesis y/o clasificadores basados en técnicas de Machine learning. Las señales utilizadas en los estudios encontrados corresponden a EDA, ECG, temperatura corporal.

De las señales anteriores se calculan algunas características importantes para la evaluación. Por ejemplo, muchas veces se utiliza el electrocardiograma para obtener el ritmo cardíaco (HR). También se calculan las medidas la variación de ritmo cardíaco (HRV), la componente de baja frecuencia (LF) y la componente de alta frecuencia (HF), similar al caso de carga cognitiva.

Se pueden combinar diferentes señales psicofisiológicas para una medición más detallada del estrés del conductor. Por ejemplo, en [203] realizan un estudio en simulador para la detección de estrés basado en rutas con obstáculos y sin obstáculos, a partir del de ritmo cardíaco (HR) y su variación (HRV), calculados desde el ECG en conjunto al EDA. Logran una precisión de 77.59 % con modelos

de estructura SVM y ANN. En [68] realizan una medición en ambientes reales de conducción y utilizando las mismas señales en conjunto con la frecuencia respiratoria, logran un modelo de detección de estrés en tres niveles (bajo, medio y alto) de 97.4 % de precisión. En este caso los niveles son categorizados según el tipo de ruta y según puntuaciones para cada conductor de acuerdo a sus gestos y maniobras registradas. En [183] utilizan la misma combinación de señales que en el estudio anterior para la detección de estrés en un ambiente real de ejecución mediante un modelo de redes neuronales convolucionales, con lo cual logran resultados de una precisión mayor al 90 % sin la necesidad de calcular características manualmente pues el modelo aprende automáticamente a combinar los datos de entrada.

En [67] también utilizan las señales de ECG, EDA y respiración en conjunto con las señales de electromiografía (EMG) para clasificar el estrés subjetivo, anotado a partir de puntuaciones de autorreporte entregados por los mismos conductores. Con un modelo de discriminante lineal logran una clasificación de 88,6 % de precisión en conducción en un ambiente real. En [1] utilizan las mismas señales sin la necesidad de generar características, creando un modelo de red neuronal con selección de características considerando el conjunto de señales como una matriz en dos dimensiones (estrategias de selección de características usadas comúnmente en imágenes), que entrega una precisión de 98.2 % al clasificar niveles bajo, medio y alto según el tipo de ruta, ciudad, autopista o descanso y validados por autorreporte de los conductores.

En [145] utilizan nuevamente el conjunto de datos de EDA, ECG y respiración en conjunto con información del vehículo obtenida mediante los sistemas de Controller Area Network (CAN-bus) en un ambiente real. Con el uso de un modelo de red bayesiana logran clasificar el estrés y no estrés, etiquetado en base a puntuaciones de autorreporte de los mismos participantes, con una precisión de 82 % al utilizar sólo las señales psicofisiológicas y un 96 % añadiendo información de los eventos.

En [161] utilizan una combinación entre las señales de EDA, HR y presión arterial, señales que muestran un aumento estadísticamente significativo en las tareas de conducción estresante versus las tareas de relajación llevadas a cabo

en un ambiente de simulación, etiquetadas según autorreporte y anotaciones de comportamiento analizadas por observadores.

A continuación, se muestran los estudios correspondientes a cada señal psicofisiológica y sus principales conclusiones.

### **Respuesta galvánica de la piel:**

Entre las diversas técnicas propuestas para la detección del estrés, la vigilancia de la actividad electrodérmica (EDA) es particularmente interesante para obtener información sobre el estrés interno que afecta a una persona, debido a su correlación con la respuesta del sistema nervioso simpático. Respecto a su utilización, en [41] realizan un experimento de simulación de tres escenarios, en los que se realizan eventos aleatorios (situaciones de tráfico de la vida real), eventos neutros y eventos estresantes. Se categorizan las mediciones en estresantes y no estresantes en base a una escala autorreportada por los participantes. Un análisis estadístico ANOVA demuestra que las variaciones EDA fueron significativamente mayores en el escenario estresante en comparación con el escenario neutro, que la actividad EDA era significativamente diferente entre las condiciones de estrés y las neutras para cada evento separado y que la amplitud de EDA está significativamente asociada con la experiencia subjetiva de estrés desencadenada por eventos programados y, por lo tanto, resulta ser un fuente de información significativa para la medición de estrés.

En [44] realizan otro análisis estadístico ANOVA sobre las señales de EDA, en relación a rutas estresantes y neutras categorizadas según encuestas de autorreporte de los mismos conductores en un ambiente real. Concluyen que esta señal presenta diferencias significativas entre ambas situaciones, por lo que es un buen candidato para la detección de estrés en la conducción.

En [202] desarrollan un sistema de clasificación automática de estrés, basado en una máquina de vectores de soporte (SVM), y el análisis de la respuesta galvánica de la piel solamente. Los conductores debían dirigir el volante a la izquierda o a la derecha en los intervalos fijos, establecidos por el sonido de un metrónomo. Un sonido repentino en momentos al azar permitía inducir estrés en los participantes. Identifican situaciones de estrés con un Recall del 98.18 %

considerando sólo los disparadores de sonido, y del 91.77% considerando tanto los disparadores de sonido como los cambios de metrónomo. Es interesante notar la utilización de un filtro adaptativo, que toma la señal del volante como señal de referencia, para eliminar los artefactos de movimiento que aparecen en la señal registrada, como consecuencia de los movimientos de la mano introducidos por el volante y por las vibraciones.

En [4] realizan un experimento similar a lo realizado en [202] agregando un escenario de colisión. Lo interesante es que demuestran la utilidad de la aplicación de los filtros adaptativos, al comparar las señales de EDA filtradas contra las señales capturadas con la mano quieta de los participantes.

En otros estudios combinan el uso de señales EDA con datos capturados desde otros sensores. Por ejemplo, en [106] realizan una detección de estrés con un resultado de 74.8% de precisión en base a señales EDA en conjunto a HR, sobre tareas de conducción de 3 niveles de dificultad.

Un hecho importante acerca del uso de esta señal es la ergonomía en su captura. En [17] se observa el uso de EDA en la palma de la mano, lo cual puede ser perjudicial para el buen desempeño de la tarea principal de conducción. En este estudio realizan una simulación en la que miden HR, la tasa de respiración y el EDA. Con métodos de machine learning (KNN, SVM y ANN) logran una clasificación con 77.25% de precisión para el estrés cognitivo y emocional inducido mediante preguntas y envío de mensajes de texto a los smartphones. De igual forma, en [31] utilizan el sensor de EDA en la palma de la mano izquierda y un sensor ubicado en el pie izquierdo. En este estudio además utilizan las señales de ECG y respiración para clasificar los niveles de estrés en tres categorías: bajo, medio y alto, utilizando una arquitectura de SVM, alcanzando así una precisión de 89.7%.

### **Electrocardiograma:**

Dentro de las señales psicofisiológicas que pueden ser utilizadas para la detección de estrés en la conducción, se encuentra el electrocardiograma, principalmente usado mediante las señales de HR, HRV, LF, HF y el ratio LF/HF. Por ejemplo, en [122] miden HR, LF/HF y la desviación estándar de la serie

de intervalos RR a partir de las señales ECG. Los resultados sugieren que los parámetros del dominio del tiempo y la frecuencia generaron características similares independientemente de la dirección del viaje (en el sentido de las agujas del reloj o en sentido contrario). Sin embargo, la frecuencia cardíaca no fue un indicador tan bueno que sugiriera que esta medida podría estar recogiendo algunos otros efectos inexplicables.

En [165] evidencian diferencias significativas en el promedio de la señal HRV (mRR) entre los diferentes niveles de estrés, medidos según la puntuación de la sección frustración de test NASA-TLX, en ambientes de conducción real. Sin embargo, esta se basa solo en un análisis de correlaciones.

Utilizando los conocimientos adquiridos para estas señales de ECG, en [112] estudian diferencias significativas en valores de métricas derivadas, dentro de la conducción real, en el interior de los túneles, en comparación a fuera de ellos. Observan diferencias significativas en los indicadores de estrés de HRV y LF/HF, efecto que no se evidencia en los copilotos medidos en el mismo experimento. Esto indica el efecto del estrés en el cuerpo humano y cómo la situación de un túnel (oscuridad, monotonía visual y acústica entre otros) puede llevar a la reacción de “miedo” y luego a una “inmovilidad tónica” (“hacerse el muerto”) lo que aumenta las posibilidades de accidentes de tránsito.

En [125] desarrollan un modelo de SVM-RBF que logra un 83 % de precisión en la clasificación de ventanas de tiempo de cinco minutos para las categorías de estrés y no estrés, medidos en ambientes reales de ejecución. En este estudio realizan una evaluación de modelos utilizando una amplia variedad de características extraídas de la señal HRV, tanto en el dominio del tiempo, como de la frecuencia y otros indicadores no lineales como la entropía o la transformada de fourier en tiempo reducido.

Dado que el ECG no solo sirve para la detección de estrés, sino que también se ve afectado por la somnolencia (ver sección 2.6.1), en [34] realizan un sistema de detección de estos dos estados en conjunto. Utilizan ECG para clasificar el estrés definido según segmentos de rutas clasificadas en tres categorías, alto, medio y bajo, y recorridas en un ambiente de simulación, obteniendo un rendimiento de 98.7 % de sensibilidad, 98.4 % de especificidad y una AUC del 96.9 %.

En [182] utilizan un k nearest neighbor (KNN), para clasificar situaciones de estrés definidas en tres categorías: bajo, medio y alto, en ambientes reales de conducción. En este estudio se escogen variables calculadas a partir del HRV en ventanas de tiempo y en tendencias (lo que llaman características de largo plazo). Demuestran que estas últimas son mejores para el clasificador (KNN). Su método de generación de características basado en tendencias fue superior al método basado en parámetros en lo que respecta al rendimiento del reconocimiento, obteniendo un 97.78 % de precisión. En [18] encuentran que niveles de estrés pueden ser detectados con éxito a partir de las señales de ECG solamente; con un clasificador de árbol aleatorio que permite la identificación de las tres clases de estrés, bajo, medio y alto.

### **Electroencefalograma:**

Por otro lado, también es posible el uso de señales encefalográficas para la detección de estrés basado en las respuestas cerebrales de los sujetos. Sin embargo, los sensores EEG pueden resultar invasivos e incómodos en ambientes reales de ejecución. No obstante, se han encontrado algunos estudios en los que se utilizan estos indicadores.

En [62] utilizan características derivadas del dominio del tiempo y de la frecuencia a partir de las señales encefalográficas, para alimentar diferentes modelos de machine learning que clasifican situaciones de estrés categorizadas según los valores emocionales de valencia y excitación en 2-D, evaluada por los mismos conductores, que incluye alegría (valencia positiva + excitación alta), angustia (valencia negativa + excitación alta), depresión (valencia negativa + excitación baja) y relajación (valencia positiva + excitación baja). La inducción de estrés se basa en la simulación de situaciones climáticas adversas. Su modelo SVM obtuvo una precisión de clasificación media de 97,95 %, una precisión de 89,23 %, una sensibilidad de 88,83 % y una especificidad de 94,92 %.

Las señales obtenidas del EEG también pueden ser combinadas con otros sensores. En [154] se utiliza en conjunto a señales de frecuencia cardiaca y presión sanguínea. Utilizando las bandas alfa y beta de determinados electrodos, estudian las correlaciones con otras señales en momentos de estrés gatillados por eventos de accidentes de tráfico generados en un ambiente de simulación. Los resultados

demuestran que las ondas alfa, que reflejan un estado psicológico tranquilo, abierto y equilibrado, mostraron una disminución de la actividad durante el estrés. Se observó que las ondas beta dominaban frontalmente cuando el sujeto estaba estresado mostrando una mayor amplitud.

En [124] utilizan la señal de EEG para obtener características de tales como la media, la desviación estándar, la media cuadrática logarítmica de la raíz, la energía de las ondículas y la entropía de cada banda de frecuencia. Esta información en conjunto con señales de EDA y ECG permiten clasificar situaciones de estrés, dadas por la ejecución de una tarea secundaria en la cual los conductores deben responder preguntas, con una precisión de 92 % en ambientes de simulación. Sin embargo, aunque el EEG permite mejora en los resultados, resulta complicado e incluso perjudicial, pensar en su uso en un ambiente real de conducción, ya que resulta ser demasiado invasivo.

### **Temperatura:**

Otra señal que ha sido estudiada para la detección de estrés corresponde a medidas de temperatura capturadas en diferentes partes del cuerpo. En [194] realizan un experimento de simulación de conducción en el cual se ha medido la termografía de rostro, sumado a temperatura en los dedos y medidas cardiovasculares. El estrés es categorizado según un método subjetivo de autoreporte, en el cual los conductores declaran su nivel de estrés en una escala de 1 a 10 cada 10 minutos. Los resultados muestran que la actividad simpática mediante la vasoconstricción periférica, se incrementó durante la situación monótona. En consecuencia, se observó una caída gradual significativa en la temperatura periférica de la piel, y las temperaturas diferenciales calculadas de la piel entre una parte periférica y troncal podrían ser útiles para evaluar un índice de estrés del conductor.

### **Fotopletismografía:**

La fotopletismografía (PPG, en inglés) es una técnica de pletismografía en la cual se utiliza un haz de luz para determinar el volumen de un órgano, aproximado en relación a la cantidad de luz que este refleja. Al igual que el ECG, ha sido utilizado para el cálculo de las señales de HR y sus variaciones HRV.

En [94] utilizan un wearable tipo guante con sensor PPG en el dedo para capturar HR, HRV, LF y HF junto con sensor IMU que posee un acelerómetro, giroscopio y magnetómetro para medir el movimiento del volante. Este último es utilizado para filtrar la señal y hacerla más robusta al ruido ambiental. Utilizando un modelo de SVM logran clasificar estados de estrés y no estrés inducidos por distintos escenarios en simulador y distintos tipos de maniobras, alcanzando un 95 % de precisión.

También es posible utilizar otras características derivadas de la señal de PPG, tal como se muestra en [157]. Aquí, las señales son utilizadas para extraer la altura del pulso, tiempo de aumento del PPG, tiempo de caída del PPG, periodo cardiaco y frecuencia cardiaca instantánea, además de características de HRV, LF y HF. Estos datos alimentan una red neuronal que permite una clasificación de 89.23 % de precisión para la detección de tres niveles de estrés, bajo, moderado y alto en un ambiente real de ejecución.

### **Expresión facial:**

Como se dijo anteriormente, el cuerpo presenta respuestas involuntaria ante situaciones de estrés, las cuales en ciertas ocasiones pueden ser evidenciadas a simple vista, pero con patrones de comportamiento complejos. De esta forma, una manera de abordar la detección de estrés es mediante el análisis de los registros faciales del conductor, los cuales presentan información acerca del estado emocional de los sujetos.

En [54] utilizan registros visuales de los rostros de los conductores, y mediante ciertas técnicas de extracción de características generan un modelo de clasificación basado en una arquitectura SVM, que busca la clasificación de seis emociones distintas: ira, disgusto, miedo, felicidad, neutralidad, tristeza, sorpresa. En ambiente de simulación logran una precisión de 90.5% y en ambientes reales de conducción esta métrica baja a 85%, debido a condiciones ambientales que dificultan el procesamiento de imágenes (cambios de iluminación, movimientos inesperados, entre otros). En este caso no se requiere la inducción de eventos estresantes, y se asume su presencia según las emociones asociadas, es decir, ira y disgusto.

## **2.6. Fatiga en conducción**

### **2.6.1. Definiciones**

El término fatiga se entiende como la pérdida de eficiencia y la aversión a cualquier tipo de esfuerzo [59]. Se puede clasificar en fatiga física, correspondiente al cansancio físico localizado en los músculos sobrecargados, y la fatiga mental, refiriéndose al cansancio mental que difunde la sensación de agotamiento general. Este último es un estado funcional intermedio entre los dos extremos de estado de alarma y de sueño, que se puede experimentar después o durante períodos prolongados de actividad cognitiva [20].

La fatiga mental puede manifestarse de manera subjetiva, conductual y psicofisiológica. Presenta diferentes síntomas, entre ellos, reduce el tiempo de respuesta humana [89], aumenta los bostezos [82], altera el cierre de los párpados [162], limita la tolerancia al ejercicio en los humanos a través de una mayor percepción del esfuerzo [113], genera una falta de energía y puede ser considerada como una falta de motivación [19], entre otros. Estos síntomas se pueden presentar de manera múltiple o por sí solos. Además, existen estudios que indican que la fatiga mental afecta negativamente al rendimiento en la ejecución de tareas físicas [178].

En la conducción es importante que los conductores puedan asumir el control con seguridad en determinados momentos, según el nivel de automatización del vehículo, por lo cual, se ha dado importancia al estado de transición entre la vigilancia y el sueño, como se mencionó anteriormente. En [81] se define este estado como somnolencia. Dada la similitud con el término de fatiga, en la literatura es común encontrar estudios que ocupan ambos términos como sinónimos (por ejemplo, algunas investigaciones investigan la influencia de la fatiga utilizando una escala de somnolencia). En otros casos se asume la diferencia entre estos términos, pero se asume que la fatiga generalmente se ve acompañada de la somnolencia [45]. Por lo tanto, en lo que sigue de este documento, se consideran estudios relacionados a ambos conceptos y se utilizarán indistintamente.

## 2.6.2. Efectos en la conducción

Se ha identificado la reducción de estado de alerta debido a la somnolencia/fatiga en la conducción como un peligro real y una importante causa de accidentes de tráfico [43]. Esto se evidencia en diferentes encuestas llevadas a cabo. En Canadá [25], se ha informado que el 20 % de las colisiones fatales involucran fatiga. En Estados Unidos, el 21 % de los choques mortales implicaban un conductor adormecido para el año 2014 [169] y, en la Unión Europea, entre el 10 % y 20 % de los accidentes de transporte comercial se atribuyen a la fatiga [51].

La somnolencia y la fatiga poseen efectos en el rendimiento humano en el contexto de la conducción. Estos generan un deterioro en los tiempos de reacción. En [138] se demuestra esto en ambientes de simulación, y en [77] se demuestra que cuando la cantidad de sueño (horas dormidas la noche anterior) aumentan, los tiempos de reacción de los participantes mejoran. Además, el aumento de la somnolencia está asociado con la disminución de la vigilancia, la memoria, la coordinación psicomotora, el procesamiento de la información y la toma de decisiones [103].

La fatiga se relaciona también con la disminución de la capacidad de trabajo, la falta de disposición para aplicar el esfuerzo a tareas y el aumento del malestar subjetivo [117]. Además, la comunicación e interacción con el entorno se deteriora, aumenta la irritabilidad y la reacción resulta más agresiva hacia otras personas o vehículos [23]. Incluso, en [117] sugieren que la fatiga del conductor inducida por las tareas reduce la conciencia de la disminución del rendimiento.

En relación a los otros estados psicofisiológicos estudiados, según [117], la fatiga puede coexistir con los síntomas de estrés, como la tensión y la negatividad, agravando dicho estado. Respecto a su relación con la carga cognitiva, la creciente automatización de procesos provoca la reducción de las tareas del conductor humano, lo que crea una situación más monótona en la conducción. Según [118] esto genera fatiga de forma pasiva.

Respecto a la tarea de conducción, se puede observar alteraciones en tres aspectos específicos del control: La dirección (a mayor fatiga menor rendimiento en la dirección del vehículo) [5, 73], comportamiento en tareas de seguimiento

(cambios en la velocidad relativa y distancia al vehículo líder) [73] y velocidad. Respecto a esta última, en general se observa una disminución al momento de presentarse la fatiga [149], sin embargo, existen casos en los que se aumenta la velocidad como medida compensatoria a la fatiga [64], técnica que obligaría una mayor atención por parte del conductor a la tarea.

### **2.6.3. Métodos de estimación de fatiga**

Al igual que para el caso de la carga cognitiva (véase 2.4.3) o el estrés (véase 2.5.3), no existe un método directo para la medición de fatiga. Por lo tanto, la mayoría de los estudios se enfoca en la evaluación de características que presenten diferencias significativas en momentos definidos de fatiga/somnolencia versus momentos normales. Los estados son clasificados por modelos de machine learning entrenados o estudiados mediante test estadísticos que validan el uso de ciertas características representativas.

Para conocer los momentos en los que se presenta fatiga/somnolencia, se han desarrollado experimentos en los que los participantes deben autorreportar su estado, a partir de cuestionarios subjetivos, cada ciertos periodos de tiempo [139, 151, 166], al comienzo y/o finalización de las pruebas [72, 132, 170, 171, 173]. Otra manera de conocer los momentos de fatiga/somnolencia corresponde a la detección de criterios preestablecidos [28, 46, 52, 188, 200, 201], como los bostezos, desviación de la cabeza, parpadeos, entre otros, las cuales son alertadas por un experimentador que observa a los participantes, ya sea mientras ejecutan las tareas de conducción, o posterior a los experimentos mediante registros de video [47, 50, 147]. Por otro lado, en ciertas ocasiones se asumen los periodos de mayor fatiga mediante tareas de distracción [39, 87], o periodos de fatiga establecidos por el método experimental [32, 150]. Algunos estudios utilizan las señales de EEG para detectar las etapas de transición de sueño y utilizan dichos gold standard para etiquetar los periodos de somnolencia [91, 92].

En general, dada la naturaleza del estado de fatiga/somnolencia, y el riesgo que involucra su aparición en ambientes reales, los estudios se realizan en ambientes de simulación, aunque en esta revisión bibliográfica se han encontrado ejemplos desarrollados en ambiente real [87, 143, 147, 188, 200, 201].

La fatiga es generalmente inducida por situaciones monótonas de gran duración [72, 92, 132, 147, 150] y la somnolencia mediante la privación de sueño en la noche anterior al experimento [91, 101, 136, 151, 155, 166, 195]. En algunos casos, se han desarrollado simulaciones de estos estados, en la que se le pide a los participantes que actúen de determinada manera [32, 143].

Para la medición de estos estados, se han utilizado señales psicofisiológicas, que miden las respuestas involuntarias relacionadas al sistema nervioso en presencia de la fatiga/somnolencia y registros visuales de video para la detección de reacciones visibles del cuerpo y rostro. Por otro lado, también se han utilizado datos del vehículo, para medir reacciones tales como la desviación del carril, los cambios de velocidad y/o ángulos del volante. En la siguiente sección se detalla con mayor profundidad dichos puntos.

#### **2.6.4. Análisis de la literatura**

En la sección 2.6.3 se nombran los métodos de medición de la fatiga/somnolencia: el auto reporte, el uso de medidas psicofisiológicas y medidas de rendimiento basadas en el vehículo. A continuación, se muestran estudios para las últimas dos categorías, ya que un sistema basado en el auto-reporte no tiene sentido real para la disminución de accidentes, además de ser un método sumamente invasivo en la tarea principal de conducción.

En algunos estudios combinan el uso de señales psicofisiológicas junto a medidas de rendimiento basadas en el vehículo. Por ejemplo, en [101] realizan una simulación con 35 sujetos, los cuales deben desempeñar tareas de conducción y no conducción, tales como, distracción visual, mediante el uso de teléfonos móviles, distracción cognitiva, mediante conversaciones en voz alta, o situaciones de estrés, dada por el seguimiento de un vehículo líder. En cuanto a la somnolencia, esta es inducida mediante la privación de sueño la noche anterior, donde los participantes solo podían dormir 4 horas. Las señales psicofisiológicas utilizadas incluían la frecuencia cardíaca, la frecuencia respiratoria, la respuesta galvánica de la piel y la temperatura corporal de los participantes. Además, utilizan la tasa de parpadeo, el porcentaje de cierre de los ojos y la dirección de la cara. Estos en conjunto con medidas del vehículo tales como la velocidad, la aceleración longitudinal, la

aceleración lateral, el ángulo del volante y el ángulo del acelerador, alimentan una red convolucional para la clasificación de los estados de somnolencia. Sin embargo, no se muestra una métrica clara de los resultados finales de este modelo.

En [139] realizan otro estudio en simulación en el cual los conductores debían conducir de noche por dos horas, con lo cual se induce la somnolencia. Utilizan la posición lateral del vehículo en conjunto con el porcentaje de cierre de párpados, calculado mediante el registro en video del rostro de los conductores y analizan las diferencias estadísticas en diferentes momentos y generan un modelo ARX de segundo orden, donde la entrada es la posición lateral y la salida es el ángulo de dirección. Los modelos residuales generados de esta manera muestran las tendencias esperadas y tienen el potencial de servir de base para una monitor del estado del conductor.

A continuación, se detallan estudios para las categorías de mediciones basadas en el vehículo y mediciones psicofisiológicas.

### **Estudios basados en mediciones del vehículo**

En [167] realizan un estudio de simulación en el cual los participantes deben realizar repetidamente tareas de conducción hasta que se presente fatiga. Se miden los datos sobre el ángulo de la dirección de las ruedas, los cuales son filtrados mediante métodos que involucran una transformada rápida de wavelet y el estudio de su índice de Lyapunov, demostrando la existencia de caos en las señales, que pueden ser atribuidas a la presencia de fatiga en el conductor. En [50] utilizan las señales de dirección para alimentar una red neuronal, que clasifica estados de somnolencia con una precisión de 85 %. En este último caso el estudio también fue llevado a cabo en un simulador, y las etiquetas de fatiga se registraron mediante una escala de puntuación calculada a partir de la evaluación de criterios preestablecidos.

En [171] realizan un estudio en simulador, en el que 56 sujetos debían recorrer 40 minutos en un ambiente donde, en el primer escenario, se presentaban estímulos visuales del borde de la carretera repetitivos y monótonos, mientras que en un segundo escenario, se presentaban elementos visuales dispares destinados a

perturbar la monotonía sin cambiar la geometría de la carretera. Aquí combinan los datos de la dirección con la posición lateral del vehículo y su velocidad para generar un análisis mediante el método de ANOVA, cuyos resultados muestran diferencias significativas en estas señales entre ambos escenarios y a través del tiempo. Una buena conclusión es que el contexto de la carretera también puede afectar el estado de fatiga del conductor, por lo que se debe considerar tanto para la medición como para la creación de intervenciones de contramedida.

Respecto a lo anterior, en [170] utilizan el mismo experimento y datos usados en [171], pero en este caso estudian cómo se diferencian las medidas de rendimiento del vehículo en relación a características subjetivas de cada sujeto, mediante un análisis de regresión múltiple que verifica la relación entre los predictores de la personalidad y los niveles subjetivos de alerta. De acuerdo con estos resultados, un cierto grupo de conductores pueden ser más sensibles a la monotonía de la carretera y, por lo tanto, más propensos a errores de conducción relacionados con la fatiga en entornos de carretera poco exigentes.

En [151] realizan un estudio en simulación con 14 sujetos, midiendo nuevamente las señales de velocidad longitudinal del vehículo, posición lateral del vehículo y ángulos de la dirección. Mediante diferentes características derivadas de estas señales, entre las que se encuentran la variabilidad de señales de velocidad del vehículo, posición lateral, ángulo del volante, porcentajes de salidas del carril (intervalo de tiempo fuera del carril de conducción), tiempo hasta la línea de cruce, número de inversiones del volante y movimientos rápidos del volante, alimentan una red neuronal que alcanza una precisión de 75 % para momentos de somnolencia etiquetados mediante el método KSS de autoreporte.

Utilizando diferentes medidas, en [173] se ha estudiado el tiempo de conducción segura en carretera. Mediante medidas multiobjetivas y subjetivas, caracterizan la fatiga de los conductores en un experimento de simulación, relacionando el tiempo de conducción y sus medidas de rendimiento mediante análisis estadísticos. Entre las características utilizadas se encuentran desviación estándar de la velocidad del automóvil, la desviación estándar de la posición lateral y la frecuencia de cruces de la línea de borde para los dos lados de la carretera. Concluyen que 80 minutos es el límite de conducción segura.

## **Estudios basados en medidas psicofisiológicas**

Respecto a los estudios relacionados a la medición de fatiga/somnolencia a partir de señales psicofisiológicas, se encuentran métodos estadísticos y clasificadores basados en técnicas de Machine learning. Las señales utilizadas en los estudios encontrados corresponden a EEG, ECG, Computer vision.

Se pueden combinar diferentes señales psicofisiológicas para una medición más detallada de la fatiga/somnolencia del conductor. Por ejemplo, en [132] realizan un experimento de simulación en el cual 59 sujetos conducen por una ruta monótona por 50 minutos, mientras se registra las señales de EOG, EEG, EDA, ECG y respiración, y donde cada ciertos periodos debían responder a una tarea de atención secundaria. La etiqueta de fatiga se obtiene a través de un cuestionario subjetivo realizado a los participantes. Mediante métodos estadísticos evalúan diferencias significativas de características tales como 5 categorías de apertura de párpados mediante altura máxima, tiempo de subida y tiempo de bajada, cálculo de bandas de frecuencia theta, alpha y beta para el EEG, cálculo de HR, HF, LF a partir de ECG y el tiempo de respuesta entre un estímulo y la respuesta. Los resultados muestran que existen clases dominantes de parpadeos, las cuales cambian a lo largo del tiempo de ejecución del experimento. Los parpadeos no solo se ven afectados por la somnolencia, sino también por la lucha de los conductores de afrontarla. Respecto a las otras señales, existen conclusiones acerca de la correlación a lo largo del experimento pero no son muy influyentes.

En otros estudios también se encuentra que los parpadeos pueden ser una característica útil para la detección de fatiga. En [91] encuentran que el pestañeo presenta variaciones en los momentos de fatiga del conductor. En este estudio 35 sujetos participan de un experimento en simulador, para el cual los participantes debían dormir 2 horas menos la noche anterior, y en el que son sometidos a conducción monótona por 2 horas o hasta detectar eventos de fatiga, según los criterios impuestos en la experimentación. Durante la conducción se registran las señales de EEG y EOG, HR y presión arterial branquial. Encontraron además que la actividad de las bandas delta y el theta aumentan significativamente durante los periodos de fatiga y que los valores de HR fueron significativamente menores antes de la tarea que durante su realización.

En [195] un experimento en simulador es llevado a cabo por 30 sujetos, los cuales cumplían con una privación de sueño de la noche anterior. Capturan las señales de movimiento ocular, ECG y EEG, con las cuales alimentan un modelo de red dinámica bayesiana, demostrando que el uso de las variables de ECG y EEG mejoran los resultados de detección de fatiga. Concluyen que ECG y EEG deben estar dentro de cualquier sistema de detección.

### **Computer Vision:**

Como se ha comentado anteriormente, las características relacionadas al parpadeo son útiles para la detección de fatiga en la tarea de conducción. Es por ello que múltiples estudios buscan la detección de estos rasgos distintivos a través del procesamiento de imágenes del registro visual del rostro de los conductores.

En [32] los sujetos son enfrentados a tareas de conducción en simulación, donde se registra los videos del rostro para el cálculo del porcentaje de cierre de los párpados (PERCLOS) y la dirección de la mirada. Además, calculan el porcentaje de estado de la cabeza sin movimiento a través de un sensor de giroscopio ubicado en la cabeza de los sujetos. Demuestran así que el conductor somnoliento muestra la alta proporción de PERCLOS porque la dirección de la mirada no cambia mucho y su parpadeo aumenta. Cuando el nivel de somnolencia es superior al 80 %, el sistema indica que el conductor está somnoliento. Respecto a la detección de movimientos de la cabeza, en [126] se presentan algoritmos y la metodología para ello, lo cual puede ser útil en la detección de fatiga.

Otra característica importante a considerar es la detección de bostezos. En [52] se presenta un algoritmo en base a la detección de esquinas de la boca y ratios de apertura, desde imágenes del rostro de personas. Sus resultados muestran una tasa de reconocimiento de bostezos de 95 % usando LDA en imágenes y una tasa media de reconocimiento de bostezos de 72 % al utilizar la detección de esquinas de la boca. Por otro lado, en [46] utilizan los clasificadores de árbol de decisión y SVM para la detección de bostezos en ambiente de conducción (lo cual resulta más complejo dada los cambios de luminosidad). Sus resultados muestran tasas de reconocimiento de 98.04 % y 100 %, respectivamente.

Además de los estudios anteriores, se han desarrollado metodologías para la detección de otras características visuales, no necesariamente del rostro de los sujetos, sino también de observaciones relacionadas a su postura y/o movimiento. En [39] utilizan grabaciones con cámaras Kinect en un ambiente de simulación de conducción para la estimación de la posición del brazo, orientación de la cara, rasgos faciales como la forma de la boca y el levantamiento de las cejas y estimación de la mirada y cierre de los ojos. Con esto desarrollan dos clasificadores de distracción en conductores, AdaBoost y el modelo de Markov oculto. Sus resultados muestran una capacidad de detección y reconocimiento fuerte y precisa (85 % de precisión para el tipo de distracción y 90 % para la detección de distracción).

Cabe notar que el uso de registros visuales es computacionalmente más complejo, sin embargo, parece ser un método no invasivo validado, ya que existen estudios en los cuales estos procesos se llevan a cabo en ambientes reales de conducción. En [201] muestran que es posible la detección de cierre de párpados, asimetría promedio del iris y la apertura de la boca, considerando la detección de bostezos en conducción real. Por otro lado, en [188] realizan un modelo de Discriminative Random Regression Forests (DRRF) para la predicción de somnolencia directamente desde la detección de movimientos de la cabeza, sin la necesidad de usar un sensor de giroscopio, proponiendo una alternativa menos invasiva, correspondiente al uso de cámaras Kinect. Sus modelos consiguen una sensibilidad de 94.28 % en el día y 95.13 % de noche.

En [200] utilizan registros de videos con cámaras Kinect en ambientes reales de conducción para la detección de frecuencia del parpadeo de los ojos, desviación de la postura de la cabeza por un tiempo muy prolongado y la posición de la cabeza no frontal. Los resultados muestran que se puede etiquetar correctamente la fatiga logrando predecir 28 de 30 secciones de fatiga reportadas por criterios de evaluación establecidos.

En [143] se les pide a 33 sujetos que actúen en tres escenarios de comportamiento: normal, bostezo y somnoliento durante periodos de 20 a 30 segundos. Se registran las imágenes de sus rostros en un ambiente real de conducción y se logra clasificar los tres estados con un 93.8 % de precisión.

Otra opción interesante corresponde al uso de modelos de deep learning, en el cual no se requiere el procesamiento de características. En [47] los conductores son expuestos a una conducción simulada de esquivar obstáculos, mientras se registra el video de la cara de los conductores. Cada frame de video es etiquetado en un estado de somnolencia o no somnolencia, y de esta manera, un clasificador basado en redes neuronales convolucionales logra un 88 % de precisión al entrenar sobre el mismo conductor y 78 % de precisión al entrenar sobre otros conductores. Respecto a la clasificación de eventos de fatiga en ambiente real con este enfoque, en [87] se le pide a los conductores que realicen ciertas actividades de distracción: experimento de conducción normal, mensajes de texto, llamadas telefónicas, manejo de radio navegación, alcanzar objetos en la parte trasera. Utilizando una red neuronal preentrenada, extraen características de el video de los conductores y con ellas entrenan un modelo XGBoost que logra un accuracy de 95 %.

### **Electroencefalograma:**

Aunque la detección de fatiga/somnolencia mediante aparatos de encefalograma sea invasivo en un ambiente real de conducción, se han encontrado algunos estudios en los cuales se evidencia que es posible medir la fatiga a partir de estos datos. Esto es útil para la detección de dichos estados a partir de otras señales que busquen correlacionarse a estados de mayor fatiga/somnolencia, a partir de métricas de EEG utilizadas como gold standard.

En [155] realizan un experimento fuera del ambiente de conducción, en el cual 10 sujetos que presentan hábitos de buen dormir son privados de sueño por un periodo prolongado de tiempo. Utilizan una tarea llamada auditory vigilance task (AVT) cada 1 hora dentro del experimento para etiquetar en cinco niveles de fatiga, que corresponden a la estandarización de los rendimientos de cada sujeto (cinco segmentos uniformes entre las puntuaciones del AVT). En los periodos sin AVT los sujetos realizan tareas no agotadoras. Analizan la señal EEG mediante la descomposición en 4 bandas de frecuencias (delta, theta, alpha y beta). Para cada banda calculan 4 características. Mediante un modelo de SVM multiclase, logran clasificar los periodos de somnolencia etiquetados, logrando una precisión de 87.5 %.

Respecto al uso de las señales de EEG en un ambiente de conducción, en [92] 10 conductores de camiones fueron sometidos a un estudio de simulación en el que debían conducir por un periodo máximo de dos horas o hasta alcanzar algún signo evidente de fatiga, según los criterios definidos en la experimentación. Generan un modelo con lógica booleana para la detección de 4 fases de fatiga, a partir de la magnitud (la suma de los valores) por cada segundo de datos, en cada una de las bandas de frecuencia (delta, theta, alpha, beta). El software demostró ser capaz de detectar la fatiga con precisión en 10 sujetos sometidos a prueba. El porcentaje de tiempo en que se detectó que los sujetos estaban en estado de fatiga fue significativamente diferente de la fase de alerta.

En [190] se realiza un experimento simulado en el que 9 sujetos participan en dos sesiones de conducción por periodos prolongados, en dos días diferentes cada uno. En este caso correlacionan las medidas de EEG con el estado cognitivo del sujeto medido a partir de un índice de rendimiento de la conducción, basado en medidas del vehículos tales como las desviaciones del carril. Se seleccionan los dos canales con más alta correlación para alimentar una red de inferencia difusa neural autoconstructiva. Los resultados experimentales muestran que el uso de la red neural puede predecir el comportamiento de conducción del conductor dentro de los sujetos en diferentes sesiones y obtener un resultado satisfactorio.

El EEG también se ha usado con modelos de deep learning, en la cual los propios modelos se encargan de generar las características a utilizar. En [150] se desarrolla un experimento de simulación con un máximo de 2 horas o hasta encontrar eventos relativos a fatiga, en el que se utiliza la señal de EEG, en segmentos de 20 segundos, de los cuales los primeros 5 minutos de experimentación son catalogados como estados de alerta y los últimos 5 minutos se consideran como momentos de fatiga. En este caso 32 canales son ingresados a un modelo que de manera no supervisada selecciona 31 características, con las cuales un modelo SVM optimizado logra clasificar los segmentos temporales con una precisión de 73,29 %, con un 91,10 % de sensibilidad y un 55,48 % de especificidad.

En [28] se realiza un experimento de simulación en el cual 43 participantes desempeñan una tarea monótona de conducción. En este caso generan un

modelo autorregresivo para la extracción de características y sparse-DBN para la detección de fatiga mediante datos de 33 canales de EEG. Logran una sensibilidad del 93.9 %, una especificidad del 92.3 % y una precisión del 93.1 %.

### **Electrocardiograma:**

Dentro de las señales psicofisiológicas que pueden ser utilizadas para la detección de fatiga/somnolencia en la conducción, se encuentra el electrocardiograma, principalmente usado para obtener y analizar las señales de HR, HRV, LF, HF y el ratio LF/HF. Un primer enfoque es evaluar las diferencias que surgen dada la fatiga en el ritmo cardiaco. En [166] se realiza un estudio en simulador en el cual 46 sujetos son expuestos a rutas de conducción monótonas durante una hora, junto a una privación de sueño, durmiendo dos horas menos de lo normal la noche anterior al experimento. En este caso demuestran que el ritmo vibratorio, que tiene los latidos del corazón en tiempo real del propio sujeto, medidos mediante el registro de la señal de ECG, tiene el efecto de inducir la condición psicofisiológica de desafiar la somnolencia. Por lo tanto, el ritmo cardiaco no solo demostraría la presencia de somnolencia, sino también la necesidad del conductor de mantenerse despierto.

Existe también el uso de otras características derivadas del ECG para la detección de fatiga. En [136], 12 participantes realizan una tarea de conducción monótona en simulación, habiendo dormido dos horas menos de lo normal la noche anterior al experimento. Registran la señales ECG, con la cual calculan las características de frecuencia, HRV y LF/HF, el primero utilizado en una prueba de pares de Wilcoxon de muestra dependiente, y LF/HF utilizado para alimentar una red neuronal feed forward que alcanza una clasificación de 90 % de precisión entre estados de alerta y de fatiga/somnolencia. La prueba de Wilcoxon muestra significancia estadística en los periodos de alerta y de fatiga para la característica analizada.

Una de las ventajas del ECG es su uso en ambientes reales de conducción. En [147] diez conductores deben manejar por cerca de 4 horas por rutas conocidas para ellos, donde se clasifican los momentos de somnolencia por observadores, basándose en la reducción o ausencia de movimientos sacádicos, ojos cerrados o casi cerrados durante períodos de más de tres segundos, ojos en blanco, expresión

inexpresiva o de enojo, pérdida de movimiento corporal y/o movimientos incontrolados de la cabeza, detectados en los registros de video captados durante la conducción. Registran las señales de ECG con las cuales calculan diferentes características, dentro de las que destacan la media y desviación estándar de la señal ECG, la integración diferencial fraccional, el ancho de banda que contiene el 50 % de la potencia, una medida de la asimetría del espectro, frecuencia del espectro de potencia, análisis de fluctuación perjudicial y LF/HF, las cuales muestran diferencias significativas para las pruebas emparejadas que comparan los períodos de fatiga/somnolencia y de alerta.

## **2.7. Definiciones y constructos seleccionados**

Llegado a este punto se hace necesario precisar la definición adoptada para los estados psicofisiológicos que se analizan en estudio.

Tras un amplio análisis de la literatura científica se encuentran múltiples definiciones de estos constructos. Un constructo se define a partir de una serie de comportamientos manifiestos para comprender un problema determinado. En otras palabras, se afirma que determinada conducta o conductas observadas se correlacionan con el constructo en sí. Por este motivo, es pertinente dejar en claro la definición de cada uno de los estados psicofisiológicos considerados para este proyecto. Por lo tanto:

### **2.7.1. Carga Cognitiva**

La carga cognitiva o mental se define como la cantidad de esfuerzo percibido inducido por una tarea en particular [187]. Según el modelo de recursos múltiples de Wickens el recurso cognitivo tiene una capacidad limitada por lo que el uso excesivo puede provocar un estado de sobrecarga conocido como agotamiento de los recursos cognitivos. Esta sobrecarga significa que el cerebro no puede procesar nueva información, lo que resulta en errores de procesamiento y/o ejecución [134] [80]. El manejo de recursos no solamente dependerá de la persona, sino también de la relación de sus características con la tarea desarrollada.

La carga cognitiva, también llamada carga de trabajo, caracteriza la tarea y explica la capacidad de los sujetos al enfrentarse a ella [58]. Por lo tanto, la

carga de trabajo representa el costo en que incurren los sujetos para lograr un rendimiento específico y que contempla la interacción entre los requisitos de la tarea, las circunstancias en que se realiza, las habilidades y comportamientos del sujeto [66]. Por separado ni las propiedades de la tarea ni las características del sujeto pueden explicar la carga mental. [142]. Dado lo anterior, se consideran tres aspectos en la carga cognitiva: (1) Demanda de las tareas, (2) rendimiento de la tarea principal y secundarias, y (3) el esfuerzo, es decir, la asignación consciente del recurso mental. [12].

### **2.7.2. Estrés**

El estrés se define como la respuesta corporal no específica a una combinación de demandas externas e internas, llamada estresor, que nace por el desequilibrio de las capacidades del individuo para hacer frente dichas demandas [153], influido por características propias de cada individuo. Se relaciona con la actividad del sistema nervioso autónomo.

En la tarea de conducción existen muchos agentes estresores, principalmente debido a su carácter complejo y altamente influido por situaciones externas. Entre ellos se pueden encontrar: ergonomía de la cabina, ruido ambiental, fatiga, aburrimiento, enfermedades, drogas, tráfico, el clima, la conducción nocturna, problemas personales o la carga de trabajo.

Los múltiples factores de riesgo presentes en la conducción, pueden generar estrés agudo (de corto plazo) y cuyas repeticiones llevan al estrés episódico. Es por ello que se dice que aquellas personas dedicadas a profesiones de conducción poseen un mayor riesgo de desarrollar diferentes niveles de estrés [16, 88, 176]. Finalmente, el estrés crónico es causado por eventos estresantes que duran mucho tiempo y que resulta perjudicial para la salud humana en el largo plazo.

### **2.7.3. Fatiga**

La fatiga se define como a la pérdida de eficiencia y la aversión a cualquier tipo de esfuerzo [59]. Por un lado, la fatiga física es un cansancio localizado en ciertas zonas musculares, mientras que la fatiga mental es el agotamiento mental experimentado tras períodos prolongados de actividad cognitiva. La fatiga mental

es un estado intermedio entre la alerta y el sueño [20] y en el ámbito de conducción generalmente es utilizada como sinónimo de somnolencia, correspondiente al estado de transición entre la vigilancia y el sueño [81].

La fatiga se manifiesta a través de diferentes síntomas pudiéndose presentar de manera múltiple o por sí solos. Entre ellos se encuentran: reducción del tiempo de respuesta [89], aumento de los bostezos [82], alteración del cierre de los párpados [162], limitación de la tolerancia al ejercicio a través de una mayor percepción del esfuerzo [113], generación de una falta de energía y disminución de la motivación [19], disminución del rendimiento [178] y, en consecuencia, el aumento de errores.

## **2.8. Interacción entre los estados psicofisiológicos**

El impacto negativo sobre el desempeño de la fatiga, el estrés y la carga cognitiva es bien conocido. Estos efectos pueden ser lo suficientemente amplios como para comprometer la eficiencia y seguridad de la tarea que se esté realizando. Se ha estudiado que existe una interrelación e interacción entre estos constructos, relación que es de interés de análisis para el desarrollo de un sistema de mitigación de los efectos negativos que éstos generan y, en consecuencia, conseguir la disminución de los factores de riesgo humano.

Los esfuerzos de capacitación y educación en la salud ocupacional, junto con un buen diseño del trabajo para hacerlo más satisfactorio pueden servir para minimizar algunos de estos efectos. Prestar atención y respetar las horas de trabajo, los ciclos de trabajo-descanso, los ciclos circadianos, etc., pueden reducir los errores laborales relacionados con la carga cognitiva, el estrés y la fatiga. [135]. Sin embargo, muchos de los momentos en que estos estados se presentan durante la ejecución de la tarea laboral suelen ser puntuales y episódicos, inclusive cuando se han tomado las medidas antes mencionadas, pues son detonadas por factores intrínsecos de la persona y extrínsecos de la tarea. Esto sugiere la necesidad de realizar una observación de cada operador en tiempo real.

La naturaleza del trabajo moderno, complejo y automatizado para disminuir las demandas del trabajador, incluso en sistemas bien diseñados, son propensos a eventos imprevistos que pueden generar en los operadores gran carga de trabajo

y estrés; a su vez, los requisitos operativos y las horas de trabajo pueden provocar fatiga. Paradójicamente, la automatización implementada con el fin de reducir la carga de trabajo puede resultar en sí misma una fuente de estrés [135].

Para abarcar estos eventos episódicos la asistencia informática específica al contexto proporciona un método potencial para la mitigación de los efectos de los estados psicofisiológicos en estudio para entornos de trabajo complejos. Dentro de los factores que pueden incorporarse a los modelos computacionales se proponen las propiedades de la tarea, el entorno, el desempeño del operador y su estado fisiológico [135].

En un estudio empírico, se demostró que la carga de trabajo — un constructo sobre las capacidades y limitaciones del sistema humano de procesamiento de información en el sentido de la psicología de factores humanos; y en el ámbito del estrés ocupacional equiparado con la demanda de trabajo, factor que contribuye al desarrollo del estrés, enfermedades o lesiones relacionadas — es un determinante clave de los niveles de estrés y fatiga entre los empleados que realizan tareas de fabricación repetitivas.

Los resultados ilustran los efectos significativos de la carga de trabajo sobre la fatiga y los niveles de estrés de los empleados tras analizar datos históricos sobre 82 tareas laborales en 22 lugares de trabajo distintos. La información obtenida por observación directa, entrevistas basadas en cuestionarios aplicados a los gerentes de producción y 186 trabajadores junto con análisis de videos para evaluar el desempeño y la cuantificación estimada de la demanda de trabajo permiten llegar a esta conclusión. Se concluye que el entendimiento de este enfoque sobre la interacción de los distintos estados permitiría mejorar la monitorización y gestión de los niveles de carga de trabajo con un enfoque proactivo para el manejo del estrés y fatiga dentro del contexto ocupacional [105].

Por otro lado, en un estudio enfocado a la tarea específica de conducción se propone un modelo transaccional entre el estrés y la fatiga del conductor y su aplicación ergonómica en diseño de sistemas de vehículos. Este estudio proporciona un framework para la ergonomía de la conducción observando estrés, fatiga y tangencialmente carga cognitiva [114].

El framework incorpora los factores de personalidad y estresores situacionales que pueden provocar patrones cognitivos desadaptativos que generan síntomas de estrés que a la vez desencadenan afrontamientos potencialmente peligrosos e interfieren con la atención a la tarea en cuestión. Sin embargo, este trabajo se centra sólo en el diseño de carreteras, los sistemas y la automatización de las funciones del vehículo y no en el conductor directamente.

El modelo transaccional del estrés del conductor propuesto sugiere que las contramedidas pueden estar dirigidas tanto hacia los factores ambientales que provocan la respuesta desadaptativa como hacia las cogniciones del conductor. Finalmente, da interesantes pautas sobre la implementación ergonómica del framework propuesto y de las intervenciones apropiadas para abordar el problema del estrés y la fatiga en la conducción [114].

Como hemos visto, cada uno de los estados psicofisiológicos en estudio son por sí solo un factor de riesgo y, además, pueden ser detonantes o agravantes de alguno de los otros estados. Por este motivo, en la Figura 2.2 se propone un diagrama de interacción entre los estados psicofisiológicos ya descritos. En particular, individualmente y en conjunto, se presentan como factores de riesgo en la conducción que pueden desencadenar acciones riesgosas y accidentes.

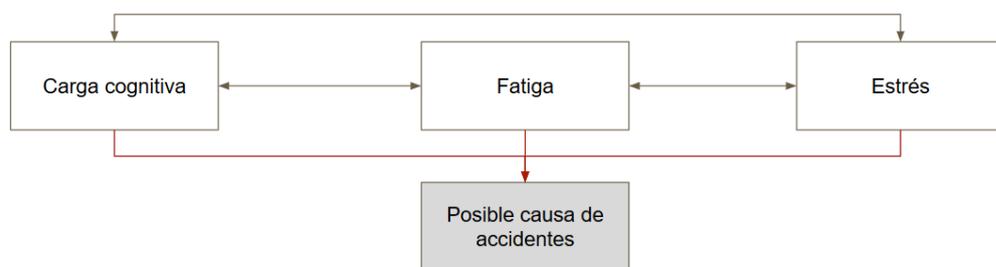


Figura 2.2: Diagrama de interacción entre los estados psicofisiológicos de un conductor que son posibles causas de accidentes.

La presencia de fatiga en conducción puede llevar a un aumento en la carga cognitiva debido al uso de recursos cognitivos destinados a la atención sostenida y al esfuerzo de mantenerse despierto mientras se conduce. En consecuencia, puede ser una causa de deterioro del rendimiento de los recursos cognitivos disponibles. A su vez, la fatiga puede actuar como factor estresante [127], el cual dependerá en gran medida de las respuestas de cada individuo ante estas situaciones. La

fatiga inducida experimentalmente por cargas de trabajo elevadas reduce el nivel de afrontamiento activo dirigido a mantener la seguridad [114].

Respecto a la carga cognitiva, esta también puede actuar como factor estresante. El estrés generalmente se asocia con niveles de carga de trabajo excesivamente altos. En general, se dice que existe una relación entre la alta carga cognitiva y los altos niveles de estrés [61, 111]. Mientras la presencia de fatiga puede crear situaciones de alta carga cognitiva, los bajos niveles de esta última, pueden desencadenar un aburrimiento y falta de motivación por la tarea en el sujeto que termina en situaciones de alta fatiga. Relaciones de baja carga cognitiva y alta fatiga se encuentran en [111].

Además, la relación entre alto estrés y alta carga cognitiva se puede observar en sentido inverso, es decir, que altos niveles de estrés requieran una asignación mayor de recursos cognitivos destinados a combatir sus efectos. De igual forma, la exposición prolongada a situaciones de estrés puede desencadenar en la presencia de fatiga.

En los estudios hasta ahora mencionados no se abarca el análisis ni la implementación de factores de mitigación mediante el monitoreo fisiológicos de estos estados en tiempo real. Es por ello que el objetivo de este proyecto es definir métodos de intervención del ambiente directo del conductor para la prevención de accidentes mediante el monitoreo psicofisiológico del conductor y la identificación de eventos de fatiga, estrés y saturación cognitiva mediante modelos computacionales que permitan la automatización de la intervención afectando mínimamente el rendimiento en la conducción considerando el diagrama de interacción propuesto en la Figura 2.2 y las sugerencias de implementación de intervenciones del framework propuesto en [114].

## **2.9. Intervenciones del entorno**

A pesar del conocimiento adquirido en las secciones anteriores, la detección de estos estados es sólo el primer paso para reducir los accidentes de conducción con somnolencia [55], carga cognitiva o estrés. Para conseguirlo es necesario un sistema de alerta que permita modificar el comportamiento del conductor en ciertos instantes para la prevención de accidentes. Por esta razón, en esta sección

se exponen diferentes estudios acerca de actuadores utilizados para intervenir ante situaciones peligrosas en la conducción desencadenadas por alguno de estos tres estados psicofisiológicos.

Basado en el hecho de que se puede detectar los momentos de mayor carga cognitiva, estrés o fatiga, se debe buscar una forma adecuada de entregar esta información, que permita lograr cambios en el comportamiento del sujeto. En ocasiones la manera en que se entrega esta información puede ser insuficiente. Por ejemplo, la información visual por sí sola puede no ser suficiente para fomentar los cambios de comportamiento, por lo que pueden resultar útiles tecnología de alerta o de calma más activas [38]. Es importante considerar que los actuadores dependen del ambiente en conjunto y no sólo del sujeto.

En el último tiempo, los vehículos han incorporado tecnologías de asistencia o sistemas de automatización con el fin de mejorar la experiencia de conducción. En particular, se espera que sea para facilitar esta tarea. Sin embargo, existe evidencia de que estos sistemas pueden generar la sensación de falta de control y estrés ante eventos inesperados [38]. Al mismo tiempo, pueden disminuir la atención del conductor, lo que conlleva a niveles inferiores a lo adecuado en cuanto a la carga cognitiva, pudiendo ser perjudicial. De esta manera diversos estudios han evaluado el uso de nuevas tecnologías a bordo del vehículo.

Por ejemplo, en [177] estudian diferentes maneras de entregar alertas de colisión a un conductor al momento de utilizar la modalidad de velocidad crucero. En particular se evalúa la ventaja de presentar información visual directiva, es decir, una flecha que indica qué decisión tomar ante una emergencia generada en el simulador. Se simularon dos escenarios, uno normal y otro con baja visibilidad por neblina. El evento de peligro es, que transcurrido varios minutos de conducción autónoma, el vehículo que va enfrente disminuye su velocidad y obliga al conductor a tomar el control para evitar una colisión. A medida que se aproxima un vehículo de frente se presentan dos tipos de alarma, entre diferentes grupos de conductores. Una alarma es visual simple acompañada de una alarma acústica, y la otra era una alarma sonora más una indicación visual de flecha que indica qué dirección tomar para adelantar. Se observa que para el grupo que recibió el primer tipo alarma existe un porcentaje de colisión de 31 %. En el caso

de la segunda alarma esta métrica fue de un 15%. Se concluye el buen uso de dar indicaciones fáciles de seguir por los conductores. Sin embargo, aunque no se detalla en este paper, el uso de velocidad crucero puede llevar a una desatención que puede resultar catastrófica.

A diferencia de lo anterior, existen estudios en los que el uso de herramientas de asistencia o automatización sí resultan ser útiles para la prevención de accidentes. En [144], estudian el uso de dos mecanismos de asistencia en situaciones reales, con participantes de diferentes edades. El primero es un sistema semi autónomo de estacionamiento paralelo asistido, y el segundo, es un sistema de alerta y de tráfico cruzado, diseñado para advertir a los conductores de la presencia de vehículos cuando intentan retroceder. En este caso miden el ritmo cardíaco a partir del ECG. Esta medida la relacionan directamente con el estrés. Por lo tanto, comparan el ritmo cardíaco en situaciones con el uso de estas tecnologías y sin el uso de ellas. Cabe destacar que no ocupan un método de detección de estrés directamente y su relación con el ritmo cardíaco puede ser un tanto simplista. Sin embargo, para el sistema de asistencia estacionamiento paralelo, logran una reducción de esta medida al utilizar la tecnología. Es significativo también el hecho de que existe una mayor excitación cuando los participantes se anticiparon al momento de estacionar de manera manual frente al estacionamiento asistido, respecto al sistema de tráfico cruzado. Aunque no se observaron diferencias estadísticamente significativas en ritmo cardíaco, se encontró que el rendimiento, medido como la tasa de frenado al retroceder y encontrar los obstáculos, mejora.

En [172] estudian cómo evitar las distracciones generadas por los sistemas de monitoreo a bordo del vehículo (IVIS). Para ello comparan cuatro escenarios: (1) en el que ninguna tarea es llevada a cabo, (2) en el que se permite hacer una tarea, (3) en el cual se le niega la posibilidad de hacer tareas y (4) un escenario en el cual se interrumpe la realización de una tarea al momento de enfrentarse a un accidente en la ruta. Esto se lleva a cabo en un escenario de simulación con 48 participantes. A través de test estadísticos determinan que la condición de denegar las tareas muestra una tendencia más consistente hacia las respuestas rápidas de frenado frente a este evento peligroso. Así, queda planteada la pregunta de si un

enfoque alternativo de entregar una alerta de la demanda mayor de conducción, de manera que el conductor tenga razones para mirar la ruta y dedicarle más atención visual, además de tener una retroalimentación de la carga de trabajo, permitiría mejores resultados. Es interesante notar que en este estudio consideran accidentes de tráfico en un ambiente simulado, sin embargo, no entregan un método de detección de este tipo de demandas externas al conducir en ambientes reales.

Continuando con un enfoque similar al estudio anterior, en [104] buscan un sistema automático de detección de los niveles de demanda en la conducción en base al tráfico y a las situaciones circundantes. En este caso combinan las estrategias de intervención, es decir, alertas que permiten proporcionar retroalimentación basada la demanda al conductor, junto con la estrategia de prevención, es decir, evitar que ciertas tareas secundarias aumenten el riesgo de colisión u otro accidente. Para ello, generan un modelo de relaciones lineales entre diferentes variables obtenidas de sensores ubicados en el vehículo, correspondientes a cámaras, ya sean frontales o de seguimiento de carril, un detector de radar para ver la distancia con los vehículos adyacentes, un sensor de ángulo de dirección y de freno. El modelo permite detectar los momentos de mayor demanda al entorno de tráfico, siendo entrenado a partir de la puntuación entregadas por los experimentadores al evaluar cada uno de los vídeos en el cual se desempeñaron las tareas de conducción. El modelo de detección logra una correlación de 0.83 lo indican que permite una predicción de demanda dinámica en tiempo real eficaz. Sin embargo, no se especifica el desempeño de este modelo en datos no conocidos, bajo el paradigma de entrenamiento y test. No obstante lo anterior, la estrategia es útil, ya que una vez conocido el nivel de demanda de tráfico, es posible tomar medidas que permitan definir qué tareas deben ser prohibidas o qué tareas no son recomendables de realizar en dichos periodos. Los resultados muestran que a una alta demanda de tareas de conducción se debe advertir o prohibir el uso de todos los dispositivos, excepto la radio y reproductor de música. Estas prohibiciones se basan en etiquetas manuales entregadas por los experimentadores quienes decidieron una puntuación de peligrosidad para cada una de las tareas consideradas.

Respecto a los métodos de intervención de entrega de información, en [71] se muestran algunas alternativas para el caso del estrés. En este estudio no se entrega una base experimental acerca de los resultados de la intervención, sin embargo, es de utilidad para estudios posteriores. La primera alternativa propuesta es un panel de conducción que cambia de colores en base a las emociones detectadas en el conductor. De esta manera al momento de mayor estrés, el panel prende con color rojo, haciendo que el conductor se percate de dicha situación. La segunda alternativa sigue el mismo principio en este caso anterior. Al detectarse emociones negativas relacionadas con el estrés, se enciende luces al exterior del vehículo, alertando a otros automovilistas, peatones o individuos en el camino. También se consideran temperatura de calma y el uso de faros correctores para evitar el efecto túnel que puede generarse por el estrés o la carga cognitiva.

Otro actuador presente en la literatura corresponde a un asiento háptico que permite regular la tasa de respiración de los conductores. En [15] realizan un experimento en ambiente real de conducción, con 24 sujetos. Durante la conducción inducen eventos de estrés a través de una tarea secundaria en la cual los participantes deben contar hacia atrás desde un número en pasos de 13 durante un tiempo determinado. Los dos minutos siguientes a la ejecución de estas tareas secundarias son conducidas mientras escucha una canción de heavy metal para que persista el efecto del estrés. Miden la frecuencia respiratoria, la frecuencia cardíaca, su variabilidad y desviación estándar a partir de un ECG. Además, consideran aspectos de seguridad como la frenada fuerte y la salida de los carriles, variables de rendimiento como la velocidad, aceleración, y tiempo de frenado. Los resultados muestran una tasa de adopción del 82 %. Los participantes reducen su tasa de respiración y excitación fisiológica basada en la raíz cuadrada de la desviación de la frecuencia cardíaca, de manera efectiva durante las condiciones post estrés. Se demuestra que este mecanismo no muestra violación de la seguridad al volante, ni cambio crítico en el comportamiento. Sin embargo, las medidas adoptadas no consideran los efectos que este actuador puede tener en los conductores que se encuentren fatigados, los cuales pueden presentar un mayor peligro en estos casos, ya que una menor frecuencia respiratoria se ha relacionado con mayor somnolencia.

Respecto a la somnolencia, según [38], esta no puede combatirse más que creando periodos cortos de atención que deben ser usados para llegar a la detención a un lugar seguro. Así en [90] realizan un framework de sistemas de alarmas en los momentos de detección de somnolencia en el conductor. En primer lugar, proponer un sistema de detección en base al comportamiento del conductor, principalmente la información de parpadeos. Para ello hacen un procesamiento de imágenes de sus rostros. El método de actuador propuesto es la utilización de notificaciones al smartphone sobre cafeterías cercanas y, en caso de ser ignoradas, información al contacto de emergencia. Como último recurso se apaga el motor. Aunque parece un método útil no lo prueban en un ambiente real de conducción por lo cual su estudio queda propuesto. Siguiendo este comportamiento, en [10] se muestran diferentes estudios acerca de tres tipos de actuadores: visuales, auditivos y mediante vibraciones; implementados con datos psicofisiológicos como el ECG, EEG y la expresión facial. Se menciona que utilizar tres niveles de detección de somnolencia, es decir, bajo, medio y alto y dos niveles para las alertas, es decir, una más suave y una más extrema, entregaría mejores resultados. En este caso la hipovigilancia considera la somnolencia y la falta de atención.

En [55] estudian contramedidas para la somnolencia detectada con modelos validados. Entregan alertas del tipo audio-visual, háptica o la combinación de ambas. La condición visual es un símbolo de taza de café que se enciende. En el caso del audio eran alertas sonoras cortas. La modalidad háptica corresponde a una vibración en el asiento. Consideran la manera binaria en la entrega de alertas, es decir, información en los periodos en los que se detecta la somnolencia, o escalonada por niveles, es decir, somnolencia leve, normal o alta. A través de un experimento de simulación y tests ANOVA, demuestran que las contramedidas reducen la salida del carril por somnolencia y la variabilidad de la posición del carril, aunque no hay pruebas del cambio de la somnolencia subjetiva posterior a la conducción. Es importante señalar que los datos indican que las advertencias por etapas pueden ser más eficaces que las alertas discretas, como expone [10].

Otro aspecto interesante que permite visualizar cambios en el comportamiento del conductor es el uso de diferentes sonidos o música de diferentes estilos. En [70] realizan una medición sobre 40 sujetos en un ambiente real de conducción

que considera momentos de mayor estrés relacionado a un mayor tráfico encontrado en la ruta. Realizan una comparación entre sujetos que se le permitía escuchar música a su elección durante la conducción versus sujetos que no. Los resultados demuestran que dentro de la alta congestión los participantes que no escuchaban música mostraron un estrés significativamente mayor que los que sí la escuchaban. Se dice que la música actúa como una distracción en el sentido de que asumen la porción de los recursos cognitivos o de atención que de otra manera podrían ser dirigidos hacia una situación estresante.

En [175] argumentan un punto similar al estudio anterior. Mencionan que el efecto de la música en la conducción puede explicarse mejor por su potencial de distracción, que por su potencial de excitación, y además, es facilitadora cuando se escucha a amplitudes cercanas al nivel de comodidad. Por otro lado, explican que la música compite con los recursos cognitivos. Para ello, realizan un experimento de simulación con 69 sujetos. Comparar entre un grupo de control, el cual debe conducir sin escuchar música, y un grupo de tratamiento, el cual escoge qué música escuchar mientras conduce. A los conductores se les induce estrés a partir de 11 incidentes diferentes durante la conducción. Los resultados muestran que los conductores que escuchaban música reportaron sistemáticamente niveles más altos de esfuerzo mental que los conductores que no la escuchaban. Además, quienes escuchaban la música rindieron al menos tan bien como los conductores que no escucharon música en todas las situaciones de conducción. Por lo tanto, se espera que a niveles adecuados, esta permita la disminución del estrés sin comprometer los recursos cognitivos necesarios para el buen desempeño de la tarea principal de conducción.

Los niveles adecuados para la música parecen depender no solo de la intensidad de sonido a la cual se escuche, sino también del estilo, cuyos efectos serían diferentes para cada tipo de conductor. En [186] realizan un experimento de simulación con 20 sujetos en el cual comparan la conducción sin música, con música ligera y con música rock, relacionada al temperamento de cada sujeto, conocido a partir de una encuesta de personalidad que considera los perfiles: colérico, de sangre, melancólicos y flemáticos. Los indicadores de rendimiento considerados fueron la desviación estándar de la velocidad, la frecuencia de cruce

de carril, la carga mental percibida y la media de la frecuencia cardíaca medida a partir de un ECG. Los resultados de tests ANOVA demostraron que la frecuencia cardíaca media, cuando se conducía bajo la influencia de la música de rock, era más alta que cuando se conducía sin música. La frecuencia cardíaca media cuando se conducía bajo la influencia de música ligera era menor que la del estado de control. Es interesante notar que para los conductores melancólicos no se puede establecer ninguna evidencia de la asociación ante el rendimiento psicofisiológico, el comportamiento al volante y su personalidad. Sin embargo, para conductores flemáticos se observó el nivel de excitación más bajo en general. Por otro lado, para los conductores de sangre, la media y variabilidad de la frecuencia cardíaca cuando se conducía bajo la influencia de la música rock eran notablemente superiores al caso de la música ligera.

Además de lo anterior, en [7] se establece que la música también afecta los niveles de somnolencia. Aquí, realizan un experimento de simulación con 30 participantes, en el cual se crean los escenarios de conducción con música y sin música. Utilizan datos del EEG para medir las bandas de frecuencia theta, alpha y beta, y así, utilizar la siguiente ecuación como indicador de fatiga:

$$2 \cdot \frac{\text{theta} + \text{alpha}}{\text{beta}}$$

Los resultados de un test ANOVA encuentran que los datos del EEG muestran efectos significativos en el valor de la fatiga luego de conducir mientras se escucha música, el cual según los valores de la ecuación anterior, disminuye.

Respecto a los sonidos naturales, en [6] realizan un experimento en un ambiente de no conducción, en el cual 40 participantes son sometidos a eventos estresantes que corresponden a tareas aritméticas cada cierto tiempo. Se observa la recuperación en base a sus señales psicofisiológicas al aplicar sonidos naturales y sonido de ambiente urbano, basadas en el SCL como índice de actividad simpática y el HRV como índice de actividad parasimpática, medidos a partir de EDA y ECG. Los resultados sugieren que después del estrés psicológico, la recuperación fisiológica de la activación simpática es más rápida durante la exposición a sonidos de naturaleza agradable.

### **3. Detección de fatiga en conducción**

En el proyecto SUSESO antecesor [78] se realizó un estudio de detección de fatiga de conductores de buses en ruta de alta montaña en base a señales psicofisiológicas y ambientales. Con el objetivo de entregar suficiente contexto para la comprensión del actual informe, se resume a continuación el experimento llevado a cabo y los principales resultados encontrados.

#### **3.1. Descripción de la tarea**

La tarea consiste en la conducción profesional de buses de traslado de pasajeros, ida y vuelta entre Santiago y la mina los Bronces, por una ruta que comprende ciudad, precordillera y alta montaña. La conducción se concibe como una tarea de atención sostenida, caracterizándose por ser no monótona y no repetitiva.

Las actividades específicas que componen la tarea son: inicio de la conducción, detención por señalética, conducción en curvas, conducción en ascenso, conducción en descenso, conducción en ciudad, conducción en camino de montaña, control de la velocidad del bus, conducción en zonas de riesgo y fin de la conducción, así como interacciones entre algunas de estas actividades. La ruta de conducción se descompone en dos tramos, “Terminal-Las puertas” y “Las puertas - Los Bronces”, siendo este último el tramo en montaña. El primero no es igual para todos los conductores ya que depende de los puntos de partida y paraderos intermedios en la ciudad. El tramo de montaña es común para todos los sujetos.

#### **3.2. Sensores y Dispositivos**

Las señales psicofisiológicas de cada conductor fueron registradas mediante la pulsera BioMonitorV2, desarrollada por el Instituto Sistemas Complejos de Ingeniería, la cual es capaz de medir las señales de temperatura de la piel, actividad electrodermal (EDA), fotoplestimografía (PPG) e inercia (aceleración y orientación), siendo esta última utilizada para el procesamiento y correcto filtro de las demás señales. Se puede observar la pulsera en la Figura 3.1.



Figura 3.1: Pulsera Biomonitor V2.

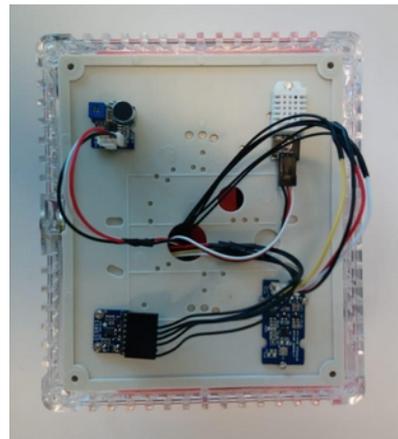


Figura 3.2: Sensor de medición de señales de contexto.

Además del registro de cada usuario, se consideran las señales contextuales de movimiento, dióxido de carbono (CO<sub>2</sub>), ruido, temperatura y humedad ambiental. Se puede observar kit de sensores de señales de contexto en la Figura 3.2.

### 3.3. Participantes

Las señales de 30 hombres, conductores profesionales con turnos de 5x2 (n=26), 7x7 (n = 3) y 6x3 (n=1), fueron registradas en sus tareas diarias de conducción hacia y en la ruta Los Bronces durante las fechas de 12/12/2018 al 28/02/2019. La edad promedio es de  $47,5 \pm 21,3$  años, todos con más de 10 años de experiencia en la tarea de conducción. Los viajes de ida iniciaron entre las 4:12 y las 6:06 horas, y terminaron entre las 7:12 y las 8:26 horas. Los viajes de vuelta se iniciaron entre las 14:08 y las 17:07 horas, y terminaron entre las 17:05 y las 21:25 horas.

### 3.4. Método experimental

La metodología de caracterización de fatiga aplicada en este experimento fue la desarrollada durante el proyecto SUSESO previo, en colaboración con IST, titulado: Caracterización de Fatiga Laboral a Través de Señales Psicofisiológicas. Para obtener detalles sobre la descripción de la metodología, favor remitirse al informe final de dicho proyecto [78].

### 3.5. Modelos de detección de fatiga

Los datos se etiquetaron para dar cuenta de tramos en que la conducción pudiera verse influida por la fatiga del conductor. A partir de las características del rendimiento en la conducción representadas en la señal del acelerómetro triaxial, se generó una métrica que permitió etiquetar tales tramos, por ejemplo, como conducción brusca, frenadas o virajes repentinos, entre otros. Los datos procesados y etiquetados se utilizaron para entrenar y probar modelos de clasificación clásicos de machine learning.

Para cada una de las cuatro sub-actividades definidas según la ruta: (1) ida ciudad, (2) ida montaña, (3) vuelta montaña y (4) vuelta ciudad, se utilizaron tres modelos de clasificación: Support Vector Machine (SVM), Multi-Layer Perceptron (MLP) y Random Forest (RF), donde a cada modelo se aplicó un método para evitar el sobreajuste de los resultados, conocido como Repeated Cross-Validation (10-fold, repetido tres veces). Previo a la ejecución de cada modelo se aplica el algoritmo de selección de características Boruta para evaluar su nivel de importancia, es decir, el poder de contribución al modelo de clasificación de cada una de las 21 características psicofisiológicas y las 10 características del sensor de contexto obtenidas. Aquellas características con bajo nivel de contribución fueron eliminadas. Además, se aplicaron modelos de aprendizaje profundo para predecir los estados de fatiga. El modelo de Deep Learning utilizado para la predicción corresponde a aquel que se conoce como Long Short-Term Memory (LSTM), perteneciente a los modelos de redes neuronales recurrentes (RNN). Estos modelos han demostrado tener gran capacidad para detectar patrones temporales y resolver problemas de clasificación y regresión, con buen desempeño cuando se trata de una variable dependiente que pertenece a una secuencia o serie de tiempo.

Para el caso de la red LSTM se realizó la predicción de la fatiga con una etiqueta distinta a la basada en la fatiga por rendimiento. Se utilizó un enfoque que explica directamente el comportamiento del sistema nervioso autónomo (SNA) que, a su vez, se subdivide en sistema nervioso simpático (SNS) y parasimpático (SNP). Para ellos se utilizó el comportamiento de la actividad cardiovascular, en específico en la observación de las componentes de frecuencia de la Variabilidad

del Ritmo Cardíaco (HRV). Este constructo se basa en que los estados de vigilia se caracterizan por un aumento de la actividad simpática y/o disminución de la actividad parasimpática, mientras que los estados de relajación y somnolencia se caracterizan por un aumento de la actividad parasimpática y/o una disminución de la actividad simpática [181] [14] [110].

El problema se abordó como una predicción de cuatro clases inducidas por el estado del SNA (despierto, estresado, fatigado y somnoliento). El objetivo del modelo es analizar señales psicofisiológicas en una ventana de tiempo dada y ser capaz de predecir con alta precisión uno de los cuatro estados del SNA en los próximos 30 segundos. Estos estados - despierto, estresado, fatigado y somnoliento - son utilizados para la predicción, que a diferencia de la clasificación de estados presentes explicado previamente, permite anteponerse a que el sujeto se encuentre en un estado cognitivo inseguro, haciendo posible tomar a tiempo acciones preventivas.

### **3.6. Resultados**

Para los modelos clásicos de clasificación se observa en su totalidad que agregar las variables de contexto mejora el desempeño. Además, en todos los casos el mejor clasificador fue Random Forest (RF), que en promedio logra una exactitud del 95,27% y un F-score de 94,39% en la clasificación del estado de fatiga según la etiqueta de rendimiento.

Para los modelos de predicción utilizando aprendizaje profundo se encontró una configuración óptima de las redes recurrentes LSTM, que permitió un excelente desempeño, con una precisión de 97,1% en la predicción de estados del SNA con una anticipación de 30 segundos.

Dentro de las conclusiones generales se destaca que el mayor poder predictor está en las variables obtenidas desde el sensor PPG (del que se deriva HR y HRV). Esto es importante porque es posible concentrar recursos en tener una señal procesada de PPG y sus variables, además, de reducir los sensores necesarios en la captura de datos de fatiga.

## 4. Detección de carga cognitiva en conducción

Utilizando los datos de los experimentos explicados en la sección 3, se desarrolla un estudio sobre la carga cognitiva en base a las demandas inducidas por diferentes tramos de conducción. El modelo se basa en la comparación de métricas derivadas de diferentes señales en los momentos de alta carga cognitiva y baja carga cognitiva.

### 4.1. Desarrollo de las etiquetas

Se extrajeron diversas ventanas de datos de la ruta en su tramo de conducción en montaña, específicamente entre los puntos de “Las puertas – Los Bronces” y el campamento “Pérez Caldera”. Éste posee diferentes zonas de riesgo, catalogadas como segmentos de alerta según la información provista por la empresa minera. Dada la localización mediante sistemas GPS en cada bus al momento de las mediciones, es posible obtener la información de las señales psicofisiológicas de cada conductor y de las señales de contexto en los momentos en los cuales se atraviesa por estos tramos.

Los datos obtenidos de estos tramos corresponden entonces a ventanas de tiempo catalogadas como alta carga cognitiva. Estos tramos corresponden a: Curva KMs 7, 8 y 9 (figura 4.1), Estrecho de Magallanes (figura 4.2), Paso Marchant (figura 4.3), Curva Estero Dolores (figura 4.4) y Campamento Pérez Caldera (figura 4.5).

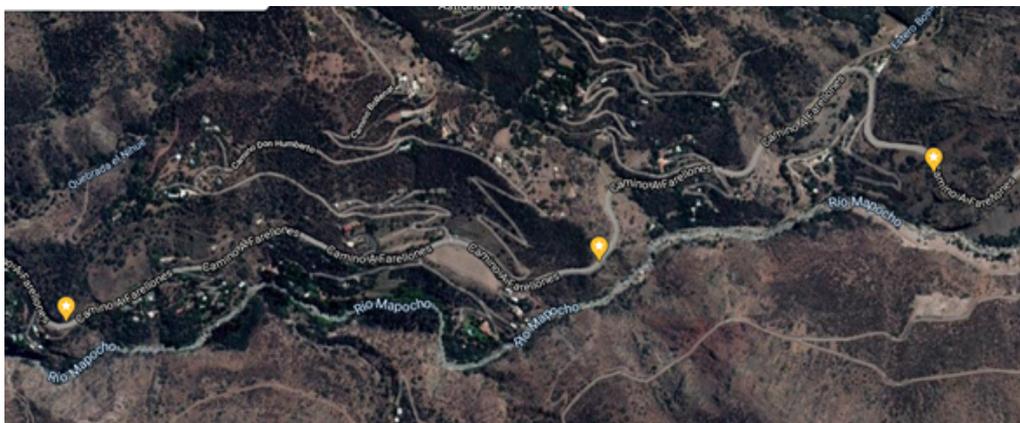


Figura 4.1: Curva KMs 7, 8 y 9.  
Coordenadas: (-70.44, -70.421, -33.373, -33.364)



**Figura 4.2: Estrecho de Magallanes**  
Coodenadas: (-70.364, -70.36, -33.33, -33.32)



**Figura 4.3: Paso Marchant.**  
Coordenadas: (-70.3496, -70.3484 -33.2615, -33.2601)



Figura 4.4: Curva Estero Dolores.  
Coordenadas: (-70.3469, -70.3399, -33.2296, -33.2255)



Figura 4.5: Campamento Pérez Caldera.  
Coordenadas: (-70.3407, -70.3371, -33.1926, -33.1867)

Para identificar momentos de menor carga cognitiva durante la conducción, se seleccionan tramos que se han considerado de menor dificultad en la ruta, correspondientes a sectores rectos, con visual amplia, relativa sensación de seguridad (por ejemplo sin precipicios) y buena calidad del terreno. Estos corresponden a Inicio Camino a Farellones (figura 4.6), Recta lo Ermita (figura 4.7), Estero Yerba Loca (figura 4.8) y Recta hasta la Plancha (figura 4.9). Los datos adquiridos durante la conducción en estos tramos serán considerados como registros de baja carga cognitiva.

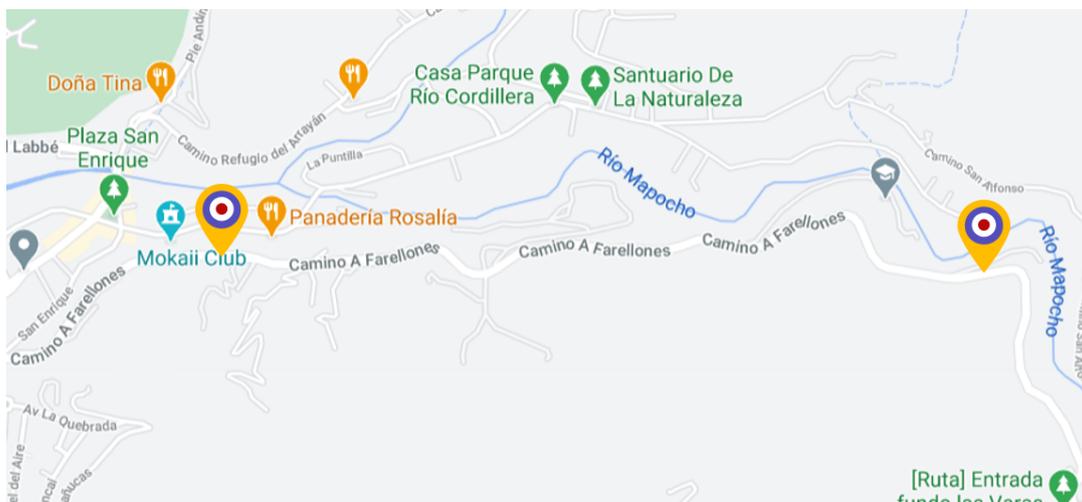


Figura 4.6: Inicio Camino a Farellones.  
Coordenadas: (-70.4928, -70.4725, -33.3667, -33.3621)

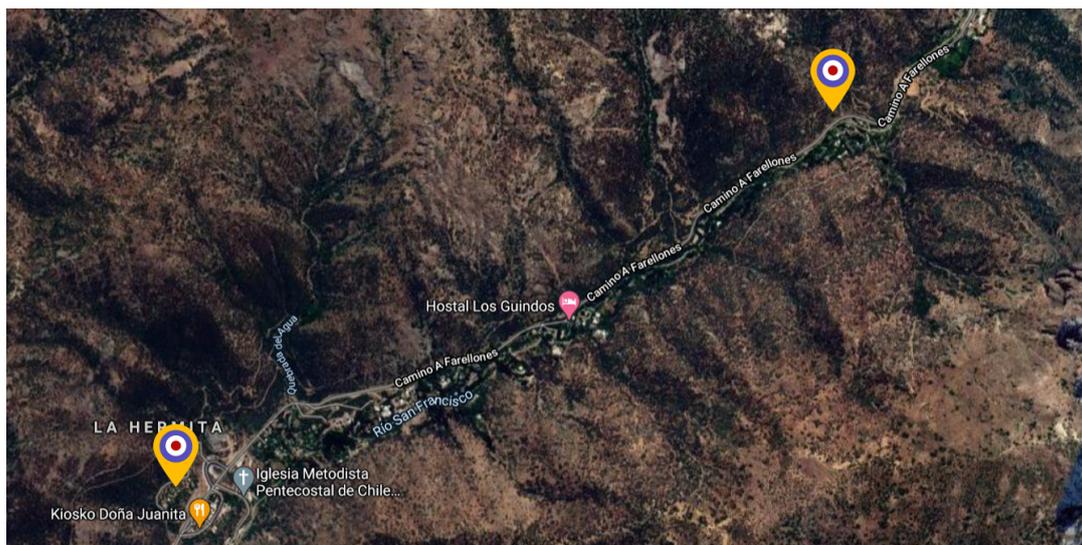


Figura 4.7: Recta lo Ermita.  
Coordenadas: (-70.3993, -70.3726, -33.3684, -33.3563)



Figura 4.8: Estero Yerba Loca.  
Coordenadas: (-70.3664, -70.3626,  
-33.3438, -33.3337)

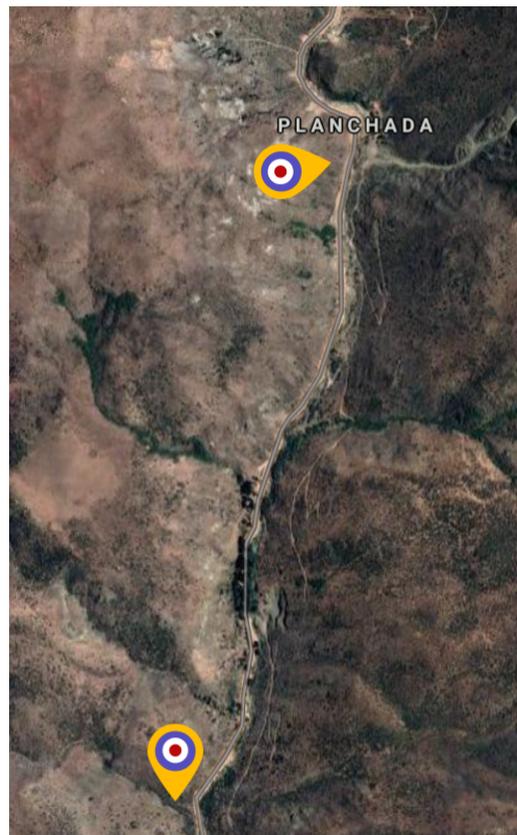


Figura 4.9: Recta hasta la plancha.  
Coordenadas: (-70.3567, -70.3502,  
-33.2954, -33.2768)

### Ruta minera segmentada

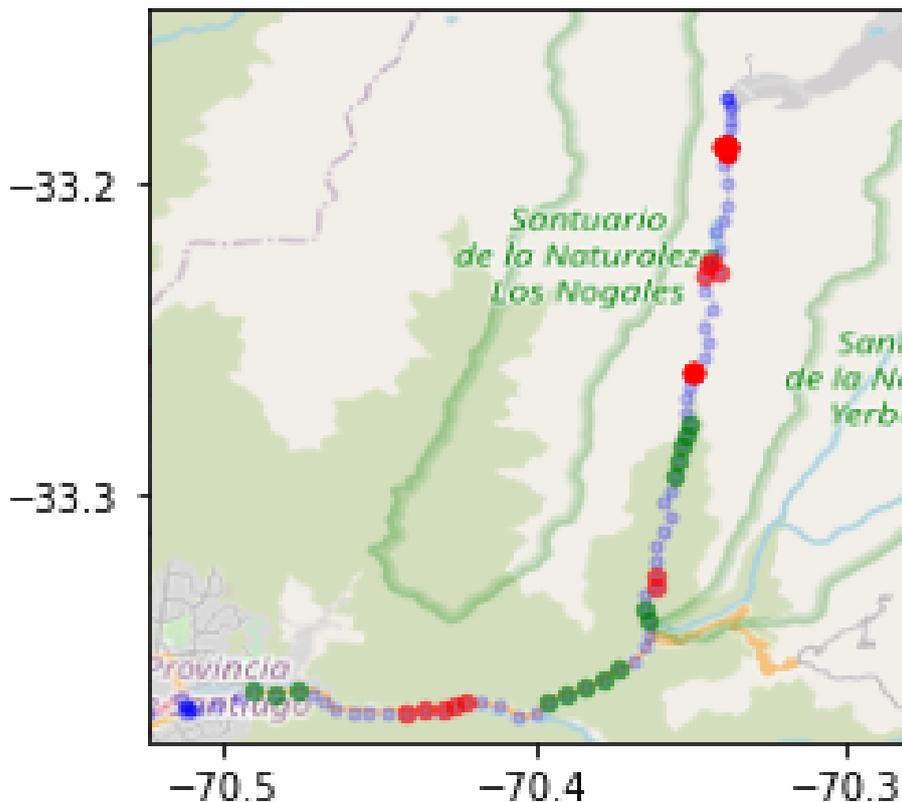


Figura 4.10: Segmentación de la ruta minera en zonas de alta y baja carga cognitiva. Elaboración propia.

De esta manera la ruta de montaña es segmentada en los momentos de alta carga cognitiva (puntos en rojo) y baja carga cognitiva (puntos en verde), como se muestra en la figura 4.10. Para estos registros, se seleccionan las siguientes señales: ritmo cardiaco (HR), variabilidad del ritmo cardiaco (HRV), actividad electrodermal (EDA) y temperatura superficial de la piel (SKT); que son rectificadas por la mediana de línea base, datos registrados previo al inicio de la conducción en estado de reposo con el objetivo de hacer comparables las variaciones entre sujetos.

Estas señales se segmentan en ventanas de tiempo de un segundo, cada una referenciando a la etiqueta respectiva al tramo correspondiente a su registro. En cada una de estas ventanas temporales se calcula el promedio de cada señal, y estas características son entonces los datos de entrada para los modelos estadísticos desarrollados en la siguiente subsección.

## 4.2. Métodos estadísticos implementados

Según lo descrito en la sección 2.3.1, para comparar dos grupos relacionados (en este caso dos tramos etiquetados de manera distinta) se utiliza una prueba estadística. Se escoge el t-test para medidas repetidas (la versión con dos tratamientos del ANOVA de medidas repetidas, también llamada prueba t para medias dependientes, muestras pareadas t- prueba, pares emparejados t- prueba y muestras emparejadas t- prueba) pues se usa para comparar las medias de dos conjuntos de puntajes que son directamente relacionados entre sí [168]. Entonces, por ejemplo, podría usarse para probar si las respuestas galvánicas de la piel de los sujetos son diferentes en dos condiciones: primero, al exponerse a una fotografía de una escena de playa; segundo, al exponerse a una fotografía de una araña.

Para este estudio se analizan las medias de las señales psicofisiológicas de HR, HRV, EDA y SKT utilizando el test estadístico t-test antes descrito, para comparar la respuesta psicofisiológica de los conductores al ser expuestos a conducir en dos tipos de tramos de la ruta: los tramos de baja carga cognitiva y los tramos de alta carga cognitiva, según lo descrito en la sección anterior. A continuación, se presentan los resultados por medida psicofisiológica y sus conclusiones.

## 4.3. Resultados

Primero se observan los gráficos de boxplot y los histogramas de cada señal para observar la distribución de los datos y la presencia de valores atípicos. Además, se calcula el t-test y se evalúa su significancia en un intervalo de confianza de 99 %, es decir, que su *p-value* sea menor a 0.01.

### 4.3.1. Análisis del Ritmo Cardíaco (HR)

La tabla 4.1 muestra para el HR una *media* = 11,56, *SD* = 25,56 y *mediana* = 5,31 para los tramos de alta carga cognitiva, y *media* = 17,33, *SD* = 29,58 y *mediana* = 12,27 para los tramos de baja carga cognitiva. Es importante recordar que a los valores absolutos del HR se le descontó previamente el valor de base obtenido para cada conductor. De esta manera, es posible realizar una comparación entre conductores. El boxplot de la Figura 4.11 y el histograma de la figura 4.12 muestran que existe una asimetría negativa de los datos, conclusión

que se complementa con que la mediana es menor que la media para ambos casos, como se observa en los datos de la tabla 4.1. La prueba de hipótesis muestra que existe una diferencia estadísticamente significativa ( $t = -22,92$ ,  $p = 2,2E - 16 < 0,01$ ) en las medias del HR entre los tramos con baja y alta carga cognitiva.

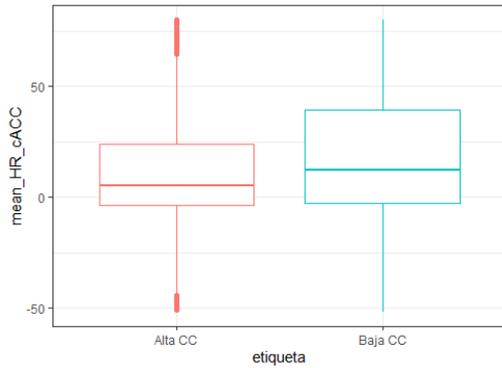


Figura 4.11: Boxplot señal HR

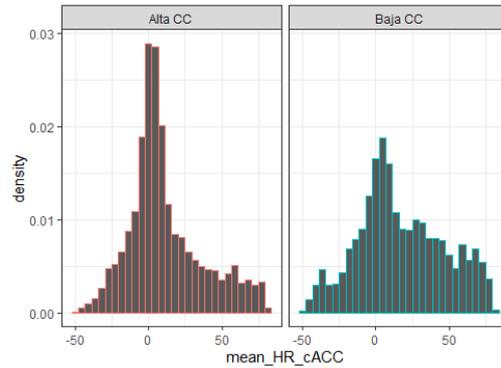


Figura 4.12: Histograma señal HR

-	Media	Desv. estándar	Mediana
Alta CC	11.56	25.56	5.31
Baja CC	17.33	29.58	12.27

Tabla 4.1: Resumen métricas estadísticas HR

#### 4.3.2. Análisis de la Variabilidad de Ritmo Cardíaco (HRV)

Para las medias del HRV se obtuvo una diferencia estadísticamente significativa entre los tramos con alta y baja carga cognitiva ( $t = -13,58$ ,  $p = 2,2E - 16 < 0,01$ ). Además, como muestran las Figuras 4.13 y 4.14 y la tabla 4.2, se observa que el HRV es mayor para los tramos de baja carga cognitiva.

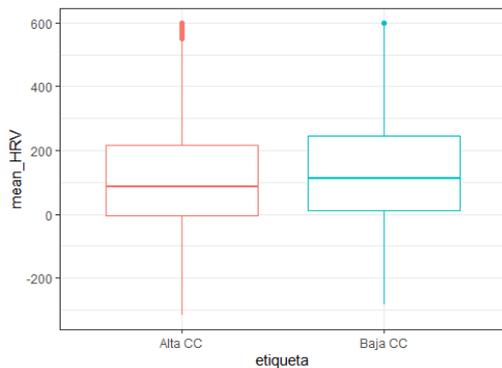


Figura 4.13: Boxplot señal HRV

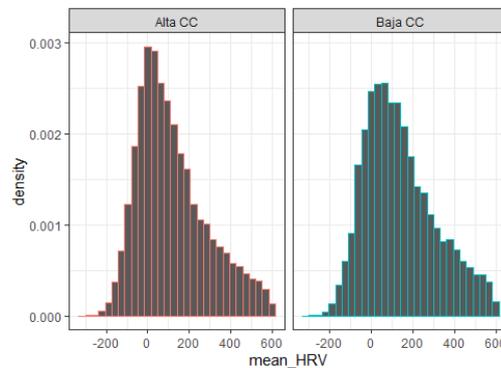


Figura 4.14: Histograma señal HRV

-	Media	Desv. estándar	Mediana
Alta CC	120.08	170.13	84.75
Baja CC	140.82	172.4	112.1

Tabla 4.2: Resumen métricas estadísticas HRV

### 4.3.3. Análisis de la Actividad Electrodermal (EDA)

La prueba de hipótesis muestra para las medias del EDA diferencias estadísticamente significativas ( $t = -11,39$ ,  $p = 2,2E - 16 < 0,01$ ) entre ambos tipos de tramos. Además, de la tabla 4.3 se observa que el valor promedio del cambio del EDA es mayor para los tramos de baja carga cognitiva que para los de alta. Las figuras 4.15 y 4.16 muestran que las variaciones se concentran entorno a cero, variaciones muy pequeñas en amplitud respecto a la línea base.

-	Media	Desv. estándar	Mediana
Alta CC	0.6535	2.0584	0.3145
Baja CC	0.8706	2.2897	0.4338

Tabla 4.3: Resumen métricas estadísticas EDA

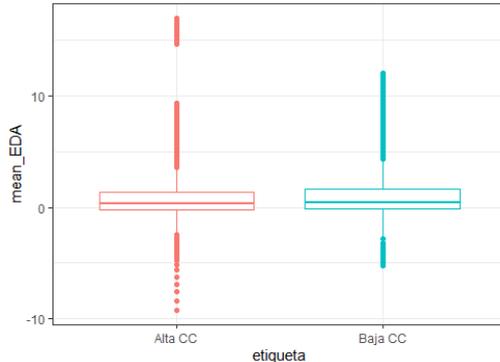


Figura 4.15: Boxplot señal EDA

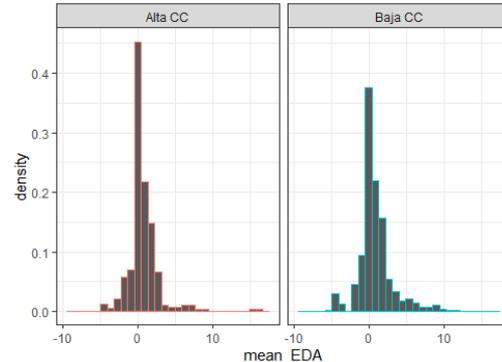


Figura 4.16: Histograma señal EDA

### 4.3.4. Análisis de la Temperatura Superficial de la Piel (SKT)

Los resultados obtenidos al aplicar la prueba t en la media de la SKT también muestran que esta señal se comporta diferente de manera estadísticamente significativa ( $t = -8,47$ ,  $p = 2,2E - 16 < 0,01$ ) entre los tramos de la ruta con alta y con baja carga cognitiva. Las métricas calculadas en la tabla 4.4 muestra una disparidad entre los valores de la media (donde es mayor para baja carga cognitiva) con los valores de la mediana (donde es mayor para alta carga

cognitiva). Esto es debido a que como se observa en el gráfico 4.17 el boxplot y el gráfico 4.18 para la baja carga cognitiva tiene una asimetría negativa de los datos versus una asimetría positiva para el boxplot de alta carga cognitiva. Este comportamiento no intuitivo de la temperatura es coherente con hallazgos previos de la literatura científica [79, 179].

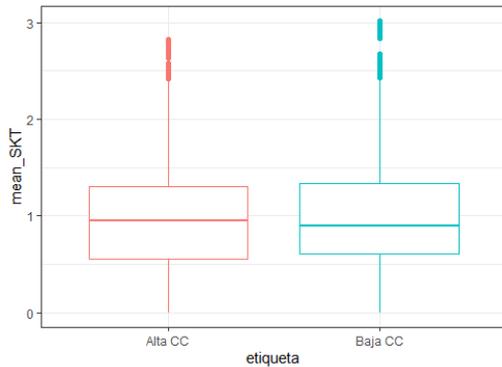


Figura 4.17: Boxplot señal SKT

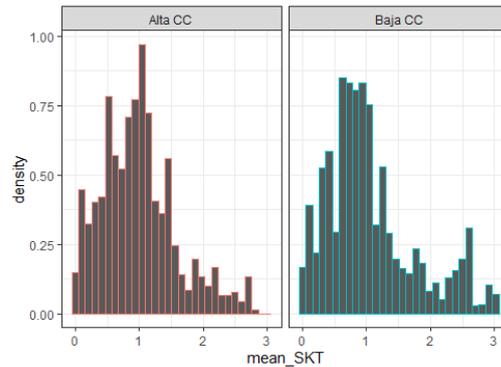


Figura 4.18: Histograma señal SKT

-	Media	Desv. estándar	Mediana
Alta CC	0,9922	0,5914	0,9524
Baja CC	1,055	0,7004	0,8994

Tabla 4.4: Resumen métricas estadísticas SKT

#### 4.3.5. Conclusiones

Se ha realizado un análisis estadístico descriptivo e inferencial de las señales psicofisiológicas de conductores de la ruta Los Bronces, descritos en la sección 3. Se ha aplicado la prueba de hipótesis t para las señales HR, HRV, EDA y SKT, de lo que se concluye que para cada caso existe diferencia estadísticamente significativa al comparar las medias de estas respuestas psicofisiológicas entre los tramos considerados de baja carga cognitiva versus los tramos de alta carga cognitiva.

Con esta conclusión es posible pasar al siguiente paso que es el análisis de características o métricas más precisas calculadas a partir de estas señales para identificar carga cognitiva presente en la conducción, dado que se ha encontrado una directa relación. Además, es posible sensibilizar este análisis considerando cada tramo por separado para caracterizar de mejor manera la ruta respecto a la carga mental intrínseca que agrega a la tarea de conducción.

## **5. Detección de estrés en conducción**

En esta sección se detalla la metodología utilizada para la adquisición y estudio de conducción en un simulador. Se explica el grupo de participantes escogidos y dispositivos utilizados, el procedimiento de captura y el protocolo experimental. Finalmente se presenta un resumen de los datos obtenidos y el análisis estadístico de éstos para la detección de estrés en la conducción junto con las principales conclusiones obtenidas.

### **5.1. Experimentos en simulador**

Dado que se desea estudiar estados psicofisiológicos que pueden ser peligrosos al ser inducidos en un ambiente real, se decide realizar la adquisición de datos en ambientes de simulación de conducción. De esta manera, es posible inducir estrés mediante eventos en la ruta, sin poner en riesgo la integridad de los participantes.

En un acuerdo con la empresa Inatrans [27], se ha establecido el uso de sus simuladores de conducción para la adquisición de datos. Este se compone del simulador de conducción modelo ENTAC con desarrollo propio, Gabinete Psicotécnico VTS (Viena Test System) y Gabinete Sensométrico Biartic. Además, cuenta con sistema de sonidos, plataforma de movimiento, sistema de visualización, sistema de proceso (modelos matemáticos de simulación), plataforma de simuladores, sistema de entrada/salida y un puesto de instructor. En la figura 5.1 se muestra la cabina donde se sienta el conductor.

El simulador cuenta con componentes originales que permite simular vehículos de las marcas: Mercedes, Volvo, Scania, Freightliner, Nissan, Mitsubishi, entre otros, pudiendo simular entre ellos: buses, mini buses, camiones, tracto camiones, vans y camionetas 4x4. Dado el acuerdo, se realizan los experimentos en simulaciones de conducción de buses.

Los escenarios de conducción simulados corresponden a adaptaciones en totalidad de las rutas reales establecidas por cada uno de los clientes de Inatrans, lo que permite replicar las condiciones del terreno en cuanto a estructura, ángulo de inclinación y pendiente, ambientación, entre otros. Dado a estas



Figura 5.1: Cabina de simulación Inatrans.

características, se cumple con todos los decretos que requieren los simuladores en Chile, asegurando una experiencia de conducción que replica lo más fielmente a una situación real de conducción en cada ruta.

El simulador permite la alteración de situaciones que dificultan la conducción, tales como: el control de la luminosidad, situaciones climáticas y de tráfico; además de incidencias del vehículo, tales como: la calidad de los frenos, el nivel de combustible, pinchazo en las ruedas, entre otros; e incidencias en la vía, tales como cruce de animales, accidentes, nivel de adherencia al camino, entre otros eventos.

Finalmente, los registros del simulador permiten comprender las fallas cometidas por los conductores en la ruta, además de entregar datos del rendimiento del vehículo, los cuales serán útiles a la hora de analizar los eventos y la reacción de los conductores a cada uno de ellos.

## 5.2. Participantes

El estudio consideró 50 conductores profesionales de  $46,8 \pm 9,95$  años de edad, todos hombres y con  $18,6 \pm 9,2$  años de experiencia en conducción en proceso de certificación para el manejo de buses de transporte de pasajeros.

Los participantes aceptan participar voluntariamente en el experimento, lo cual queda explicitado en el formulario de consentimiento informado que deben rellenar y firmar. En caso de negación, no se realiza el experimento con dicho sujeto.

### **5.3. Sensores y dispositivos**

Dado que la adquisición de datos no debe interferir con los procesos de certificación ni el desempeño de cada conductor, se debe realizar con sensores no invasivos. En particular lo que se busca medir es la respuesta de cada participante a cada evento de la ruta mediante la captura de señales psicofisiológicas, además de la información ambiental en el cual se encuentra en cada momento. Esto se realiza con los mismos sensores descritos en la sección 3.2: la pulsera BioMonitorV2.0 (ver Figura 3.1) ubicada en la mano izquierda donde se espera presente menor movimiento, y el kit de sensores ambientales y de contexto (ver Figura 3.2)

Finalmente, mediante el uso de una cámara ubicada frente al conductor, se registran los eventos faciales de cada participante, los que puedan servir como indicadores de los posibles estados psicofisiológicos.

### **5.4. Metodología de experimentación**

#### **5.4.1. Actores involucrados**

- Conductor: Se hará referencia al sujeto que lleva a cabo las tareas de conducción en una ruta determinada.
- Instructor: Persona a cargo de controlar el simulador mientras se llevan a cabo las pruebas de conducción.
- Experimentador: Persona externa al proceso de certificación, encargado de monitorear los artefactos de medición y otros factores de la investigación.

#### **5.4.2. Pre-experimento: Formularios y línea base**

Dado que las señales psicofisiológicas pueden entregar diferentes valores para cada participante dependiendo de las características propias de cada sujeto, se requiere la captura de una línea base de 3 minutos antes de comenzar la certificación, con la cual se puede conocer las variabilidades de las señales respecto al nivel basal de la persona. Esta es una captura de señales por medio de la pulsera Biomonitor, con el conductor en estado de reposo.

Es importante notar que las señales psicofisiológicas pueden estar influidas por otros factores. Por esta razón, se diseña una encuesta demográfica que considera los siguientes puntos:

- Datos demográficos de cada participante: Nombre, edad, años de experiencia en conducción.
- Calidad de sueño: Cantidad de horas dormidas la noche anterior al experimento.
- Horario en que se lleva a cabo el registro.
- ¿Durmió bien anoche?
- Dificultad percibida de la tarea desarrollada: escala 1-10.

Esta información permitirá una mejor caracterización de los resultados y el análisis en caso de encontrar problemas con datos fuera de rango.

#### **5.4.3. Experimento: Certificación de conducción en simulador**

El proceso de certificación de conductores se realiza individualmente y consta de una presentación del equipo, habituación al simulador, ejercicios en un patio de maniobras (simulado), ejercicios en ruta y retroalimentación, todo bajo supervisión de un instructor.

El experimento inicia con la etapa de aclimatación al simulador con la presentación del equipo por parte del instructor al conductor: le señala la ubicación de los pedales, controles, espejos y tipo de caja de cambio con el que realizará la certificación. Luego, se le indica al conductor que dispondrá de 10 minutos para conducir en un patio de maniobras donde se le instruye de utilizar

la totalidad del vehículo y en particular ensayar la reversa al estacionarse en un lugar indicado por el instructor.

A continuación, se inicia la certificación con la conducción en ruta la cual tiene una duración de 25 minutos aproximadamente, donde se activan una serie de eventos de diferente tipo. En la Tabla 5.1 se presenta a modo de ejemplo, el itinerario de eventos en la ruta para la certificación. Sin embargo, en la realidad los eventos son seleccionados y activados de manera manual por el instructor.

Tabla 5.1: Itinerario de eventos ruta de certificación

<b>Tiempo</b>	<b>Evento</b>
0:00	Puesta en Marcha
4:00	Conducción nocturna
5:00	Vehículo accidentado en ruta
6:00	Clima con baja visibilidad
12:00	Animal en la vía
15:00	Reventón de neumático delantero
17:00	Condiciones climáticas adversas
25:00	Término del ejercicio.

Producto de que el experimento es una certificación real que cuyo resultado influye en el perfil laboral de los voluntarios no se realizó ninguna medición que pudiera interferir. Por este motivo no se aplican tareas secundarias ni escalas autorreportadas durante este experimento.

#### **5.4.4. Post-experimento: Consolidación y análisis de datos**

Al finalizar cada experimentación, se obtiene un conjunto de datos provenientes de diferentes registros:

- Encuesta principal de datos demográficos del sujeto.
- Señales psicofisiológicas en línea base.
- Señales psicofisiológicas durante la conducción.
- Registro visual del rostro del conductor durante la tarea principal.

- Datos ambientales.
- Registro manual de eventos tomado por el experimentador.
- Datos de rendimiento y telemetría entregados por el simulador.

#### **5.4.5. Protocolo experimental**

A continuación se presenta el protocolo experimental seguido durante el estudio en simuladores.

##### **Antes del experimento**

1. Experimentador se presenta en el lugar de trabajo con baterías cargadas y todos los dispositivos y aplicaciones dispuestas para una actividad experimental fluida.
2. Dar la bienvenida y la descripción general del experimento y asegurar la firma del consentimiento informado y cualquier otro documento, si corresponde.
3. Instalar sensores al participante. Verificar la comodidad y funcionamiento.
4. Registrar línea base de las señales del participante. Etapa de medición de 3 minutos sin estímulos en posición relajada.
5. Rellenar formulario de datos demográficos y situación del participante.
6. Instalar el sensor de contexto directo en la cabina del conductor. Validar su funcionamiento correcto.
7. Validar funcionamiento de cámara en la detección de registro visual de la cara del conductor.
8. Sincronizar los tiempos de captura de la pulsera, sensor de contexto y cámara.

##### **Durante el experimento**

1. Supervisar el funcionamiento y correcta medición de los sensores, durante todo el experimento.

2. Registrar tiempo e información relevante de eventos del simulador lanzados por el instructor.
3. Dar por finalizado el experimento cuando el participante termina la tarea al completar la ruta de certificación en el simulador luego de la indicación dada por el instructor.

### **Después del experimento**

1. Indicar término de la actividad.
2. Detener y retirar los sensores. Se finaliza la toma de datos.
3. Preguntar y reportar cualquier situación relevante para el análisis posterior (situación anómala o incómoda, mareos, estrés, sueño, etc.).
4. Rellenar formulario de estados psicofisiológicos auto percibidos.
5. Despedida del participante y agradecimiento por participación.
6. Descargar y almacenar debidamente los archivos de los distintos sensores.
7. Descargar datos de rendimiento del participante y medidas del simulador.

## **5.5. Consolidación y resumen de datos**

Se logra ejecutar y registrar datos de un total de 50 certificaciones. De estas, existen dos casos en que se certifican camionetas 4x4 de las cuales no se obtienen los informes de rendimiento por lo que se dejan fuera. Del resto de mediciones, existen algunos datos perdidos como se presenta en la tabla 5.2 donde se muestra la cantidad de mediciones correctamente capturadas versus los registros erróneos, considerando cada tipo de registro o sensor utilizado. De esto, se calcula una tasa de pérdida de registros de un 26 % de los datos totales.

Tabla 5.2: Cantidad de registros

	BioMonitor	Contextin	Videos	Eventos	Telemetría	Completo sin cámara
Registros correctos	37	44	35	44	48	34
Registros erróneos	13	6	15	6	2	16

Del conjunto total de las mediciones ejecutadas, se utilizan 37 mediciones correctamente adquiridas y en completitud, sin considerar el registro de video.

Tomando los 37 participantes seleccionados, en la Tabla 5.3 se muestra el resumen de las respuestas entregadas a la encuesta demográfica desarrollada con los datos de: edad, años de experiencia laboral como conductores profesionales, cuántos declararon dormir bien la noche anterior y cuántas horas de sueño y, finalmente, la dificultad percibida de la certificación.

Tabla 5.3: Datos demográficos

Edad	Años de Experiencia Laboral	Durmió bien anoche	Horas de sueño	Dificultad percibida
46,8 (9,95)	18,6 (9,2)	30 / 37	6,9 (1,7)	6,81 (1,61)

### 5.5.1. Datos fisiológicos y de contexto

En primer lugar se consideran los datos adquiridos por la pulsera Biomonitor v2.0. De esta se obtienen las señales crudas de Actividad Electro dérmica (EDA), Fotopletismografía (PPG), Temperatura de la piel (SKT) y Acelerómetro (ACC). El acelerómetro es usado para filtrar las otras señales respecto a ruidos por movimiento. Con la señal de PPG es posible obtener la señal de ritmo cardiaco (HR) y variación de ritmo cardiaco (HRV).

En la Figura 5.2 se muestra un ejemplo de la medición de un participante. En líneas discontinuas se presentan los eventos y las cruces rojas representan los errores cometidos según el reporte del simulador. Los puntos suspensivos es el tiempo de medición entre que el usuario sube al simulador, realiza el ejercicio de patio de maniobras y empieza el ejercicio de certificación. Con fondo verde se muestra la señal correspondiente a la línea base.

Dentro de los datos de contexto se obtienen las señales de aceleración, giroscopio y magnetómetro en los ejes (x,y,z) con los cuales se puede conocer el movimiento de la cabina de conducción. Además de ello se obtienen los datos de presión atmosférica, altitud, CO<sub>2</sub>, temperatura, humedad, ruido y luminosidad. Sin embargo, estas últimas son constantes por el ambiente controlado del simulador que cuenta con aire acondicionado.



### 5.5.2. Datos telemétricos

Luego de cada certificación, el simulador arroja un conjunto de datos telemétricos, considerando datos del recorrido como: tiempo, distancia recorrida, velocidad, aceleración, uso de freno, de acelerador y embrague; en conjunto a datos del estado del vehículo: Revoluciones por minuto (R.P.M.), temperatura del agua, temperatura del aceite, consumo de combustible, entre otros. En la Figura 5.3 se presenta un gráfico de las señales telemétricas medidas para un usuario donde, por ejemplo, se puede observar con claridad la reducción de la velocidad ante eventos en la ruta.

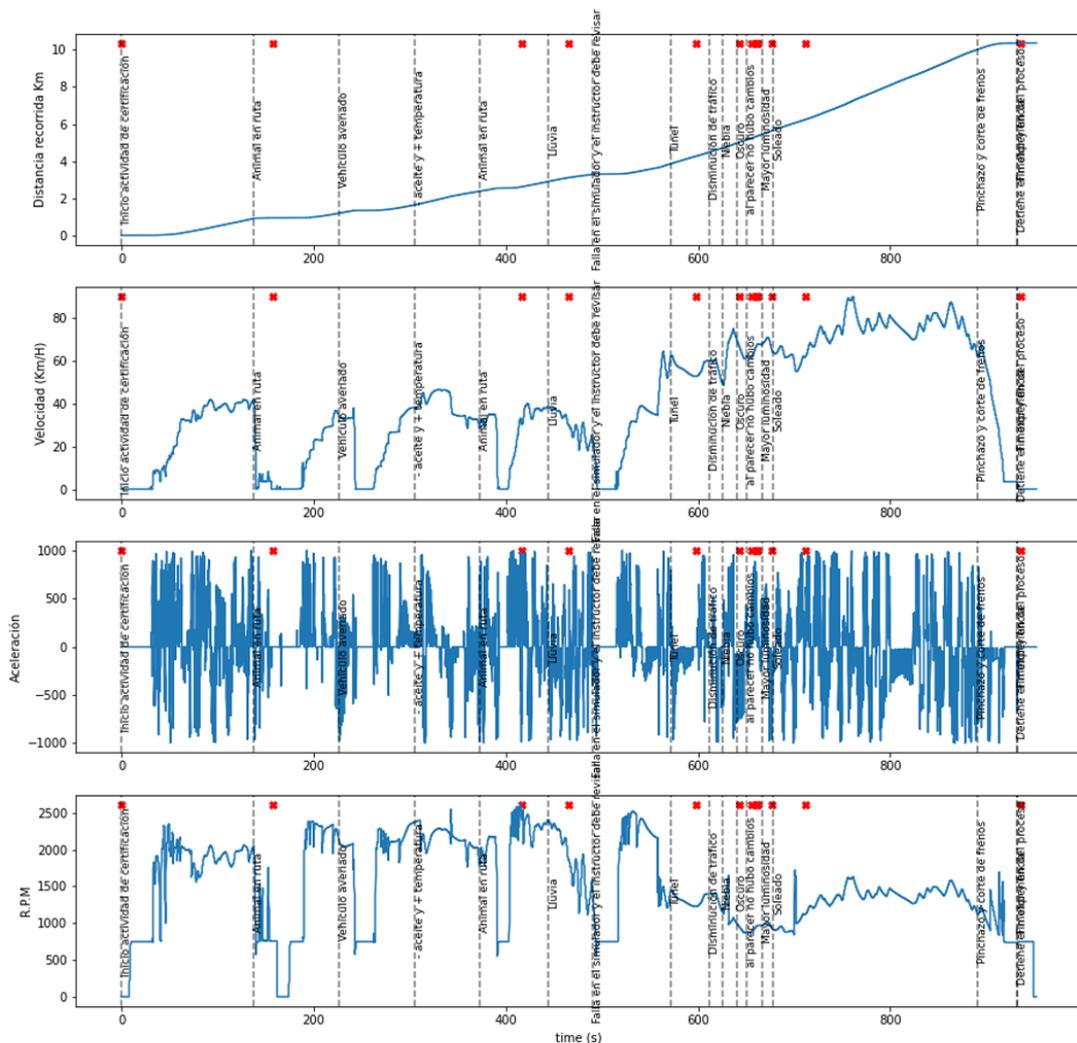


Figura 5.3: Ejemplo de datos telemétricos en la certificación

### 5.5.3. Eventos registrados

Durante la certificación el instructor activa una serie de eventos para poner a prueba la atención, la reacción y la capacidad de resolver problemas durante la conducción. Por aparecer de forma sorpresiva estos eventos resultan en estresores para el conductor. En la Figura 5.4 se muestra la frecuencia de eventos activados para el conjunto de participantes donde se debe considerar que no todos los participantes observaron cada evento y que a algunos se les presentó un mismo evento más de una vez.

Los eventos se categorizan según su origen. Están los eventos climáticos como: lluvia, día soleado, neblina, nieve, noche, arena, viento; los de fallas en el vehículo como: cambio de niveles (temperatura, presión, combustible), pinchazo, bloqueo de ruedas y quedar sin frenos; y los eventos relacionados con la ruta, como: animal, vehículo averiado o bicicleta en el camino, y mayor, menor o sin tráfico.

De estos era regular que en las certificaciones se presentara eventos de tipo animal o vehículo averiado en la ruta más de una vez, que se presentara lluvia en distintas intensidades y que se terminara la certificación con un pinchazo y/o al quedar sin frenos. Otro detalle interesante es que el evento de cambio de niveles era uno de los menos percibidos por los conductores.

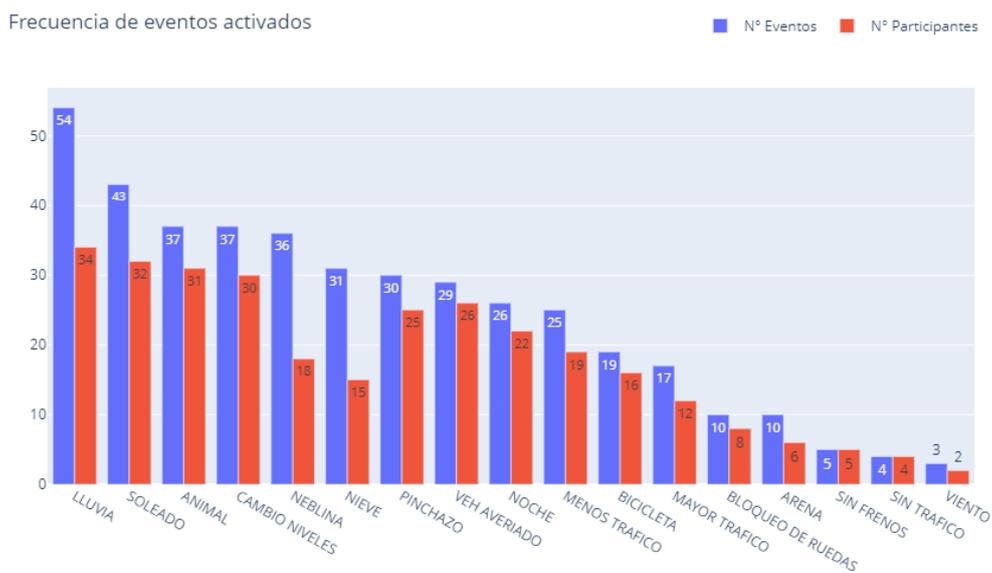


Figura 5.4: Frecuencia de eventos para el conjunto de participantes

#### **5.5.4. Errores durante la certificación**

El informe arrojado por el simulador al finalizar la certificación registra los errores detectados durante la conducción. Los errores eran clasificados como errores leves como: no conectar/desconectar los limpiaparabrisas, no pisar el freno para darle arranque al vehículo, y que se pare el motor; errores medios como: no encender luces, frenadas bruscas o tomar curva con embrague; errores graves como: conducir con revoluciones excesivas, no respetar la distancia mínima al vehículo precedente; y errores eliminatorios como: conducir contra el tránsito, superar el límite de velocidad y la colisión.

Como se muestra en la Figura 5.5 el error más frecuente es ir contra el tránsito, sin embargo, se desestima su grado de error producto del sesgo que existe de las dimensiones del vehículo al observarlo por las pantallas del simulador, el instructor también desestima este error en su evaluación.

El error eliminatorio más frecuente fue la colisión con algún elemento detenido en la ruta, como un animal o vehículo averiado. Tanto el evento como la colisión son estresores de alto grado de activación. Otra causal de la colisión durante la certificación fue la frecuencia del error grave de no respetar la distancia mínima al vehículo que precede en situaciones de alto tráfico.

Finalmente, se ha agregado a la lista de errores arrojados por el simulador la situación de sentir mareos durante o después de la certificación. De estos uno de los participante reporta el mareo al inicio de la certificación luego de la etapa de ambientación en el patio de maniobras después de descansar unos minutos puede continuar con la certificación sin problemas. El instructor reporta que existe un pequeño porcentaje de los conductores que se suben al simulador que presentan mareos.

Los otros dos casos declaran sentir mareos al terminar la certificación. Estos casos tienen en común que declaran haber dormido mal y pocas horas la noche anterior, 4 horas y media en un caso y sólo 2 horas en el otro. En el caso de este último presentó la medida compensatoria a la posible fatiga presentada al conducir a baja velocidad en el último tramo de la certificación por lo que el instructor le dio la indicación de aumentar la velocidad.

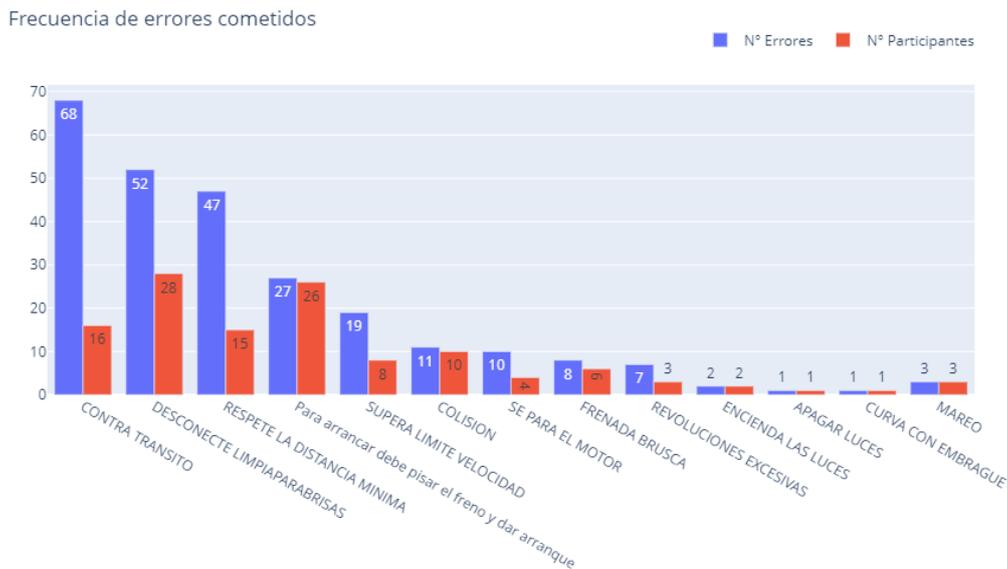


Figura 5.5: Frecuencia de errores para el conjunto de participantes

## 5.6. Análisis de datos y resultados

Durante la certificación cada conductor fue expuesto a una serie de eventos estresores ya descritos en la sección 5.5.3. Para su análisis se aplican pruebas estadísticas, como se explica en la sección 2.3.1, para estudiar el efecto de estos eventos en sus respuestas psicofisiológicas con el objetivo de encontrar biomarcadores de estas señales para detectar el estrés.

Tal como se realiza en la sección 4.2 se aplica un t-test pareado (o de medidas repetidas) para comparar características de las señales psicofisiológicas registradas en una ventana de tiempo previa al evento estresor versus una ventana de tiempo inmediatamente después del evento. Producto que el estrés genera una activación del sistema nervioso autónomo (simpático y parasimpático) se desea comprobar la hipótesis de que ciertas características psicofisiológicas tienen un cambio estadísticamente significativo al someter a estrés al conductor.

Se escoge este test por ser el apropiado para variables dependientes como en este caso y porque funciona bien para muestras de tamaño pequeño. Para aplicar el t-test pareado se requiere verificar el supuesto de normalidad de la muestra usando la prueba de Shapiro-Wilks y que no contenga valores atípicos. Si no se cumplen los supuestos se aplica el test Wilcoxon, la versión no paramétrica.

El tamaño de la ventana de tiempo escogida es de 10 segundos tanto para la ventana previa como para la ventana post evento. Se escoge este tamaño pues para la ventana previa se reduce el efecto las fluctuaciones normales de las señales y de los posibles valores fuera de rango. Además, para considerar el tiempo de reacción de las señales con mayor latencia como la señal EDA.

Cada señal ha sido procesada para eliminar los valores fuera de rango, el ruido en la señal y los artefactos de movimiento. En particular, de la señal EDA se somete a una descomposición para obtener las señales SCL y SCR, su nivel y el potencial de respuesta, respectivamente. También la señal PPG se procesa para obtener las señales HR y HRV, ritmo cardiaco y su variabilidad. En total, entre las señales capturadas y sus derivadas, se analizan 7 señales distintas: EDA, SCR, SCL, PPG, HR, HRV y SKT.

A modo de ejemplo, en las Figuras 5.6 y 5.7 se presentan las señales de SCL y SCR, derivadas del EDA, donde se señala la ventana previa y la ventana posterior sobre cada evento, ventanas sobre las que se calculan las métricas.

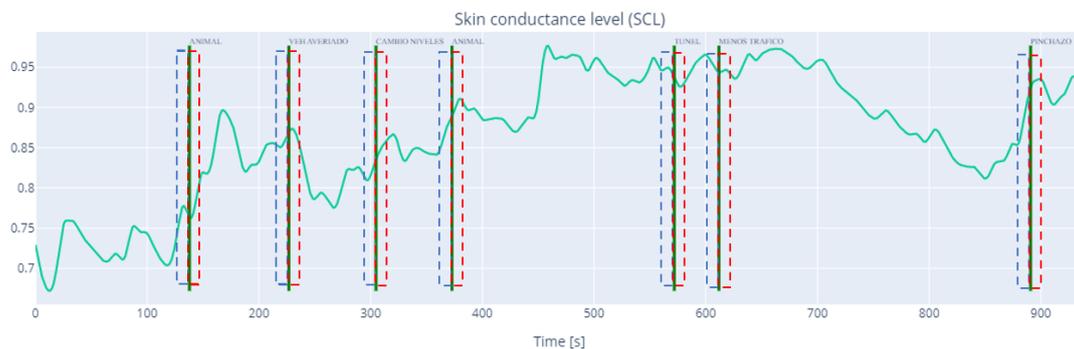


Figura 5.6: Frecuencia de errores para el conjunto de participantes

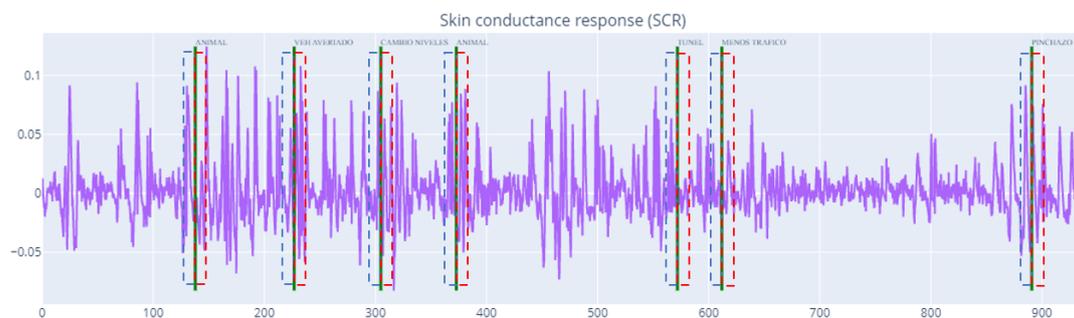


Figura 5.7: Frecuencia de errores para el conjunto de participantes

### 5.6.1. Características psicofisiológicas calculadas

Para calcular las características de las señales psicofisiológicas que se analizarán se ha restado previamente el promedio de la línea base calculada para cada conductor con el objetivo de hacer comparables entre sujetos los rango de valores de las características obtenidas.

Para cada una de estas señales se calcula una amplia batería de características que serán probadas estadísticamente una a una para verificar si existe alguna diferencia significativa entre la ventana de tiempo previa y la ventana posterior al evento estresor. Las características calculadas por cada señal se presentan en la Tabla 5.4.

Tabla 5.4: Características calculadas para cada señal psicofisiológica

Señal	Característica
EDA	Mean, Std, Median, Min, Max, Range, Kurtosis, Skew, Pendiente PsdMin, PsdMax, PsdVar
SCR	Mean, Std, Median, Min, Max, Range, Kurtosis, Skew, Pendiente MeanPeakAmplitude, SumPeakAmplitude, MeanRiseTime SumRiseTime, MeanRecoveryTime, SumRecoveryTime, AUC
SCL	Mean, Std, Median, Min, Max, Range, Kurtosis, Skew, Pendiente
PPG	Mean, Std, Median, Min, Max, Range, Kurtosis, Skew, Pendiente
HR	Mean, Std, Median, Min, Max, Range, Kurtosis, Skew, Pendiente
HRV	Mean, Std, Median, Min, Max, Range, Kurtosis, Skew, Pendiente
SKT	Mean, Std, Median, Min, Max, Range, Kurtosis, Skew, Pendiente

El total de 73 características considera métricas de cálculo estadístico y otras directamente relacionadas a las propiedades de cada señal con el objetivo de observar el estado psicofisiológico del estrés [156].

### 5.6.2. Resultados pruebas estadísticas señales psicofisiológicas

Para aplicar la prueba estadística para cada característica se verifica previamente los supuestos para t-test pareado, cuando no se cumplen se usa el test Wilcoxon. Analizando todos los eventos (excepto los de tipo climático) de las 73 características se obtiene un subconjunto de 39 métricas que presenta una significancia menor al 0.05, es decir, que valida la hipótesis con al menos un 95 % de probabilidad. El resumen de los resultados se presenta en la Tabla 5.5.

Tabla 5.5: Características psicofisiológicas con significancia menor a 0.05 para todos los eventos

<b>N</b>	<b>Característica</b>	<b>Test</b>	<b>Dif.Media</b>	<b>Tendencia</b>	<b>p-valor</b>
1	SCL_T_Mean	Wilcoxon	0,0197	Ascendente	2,06E-07
2	SCL_T_Median	Wilcoxon	0,0218	Ascendente	2,19E-07
3	HR_T_Min	Wilcoxon	1,1279	Ascendente	5,21E-07
4	SCL_T_Max	Wilcoxon	0,0206	Ascendente	7,72E-07
5	SCL_T_Min	Wilcoxon	0,0117	Ascendente	7,87E-07
6	EDA_T_Mean	Wilcoxon	0,0225	Ascendente	1,36E-06
7	EDA_T_Max	Wilcoxon	0,0337	Ascendente	1,68E-06
8	EDA_T_Median	Wilcoxon	0,0240	Ascendente	6,34E-06
9	HR_T_Kurtosis	Wilcoxon	-0,0005	Descendente	6,97E-06
10	HR_T_Mean	Wilcoxon	1,1053	Ascendente	7,88E-06
11	HR_T_Std	Wilcoxon	-0,3282	Descendente	1,42E-05
12	HR_T_Pendiente	Wilcoxon	-2,8154	Descendente	1,66E-05
13	HR_T_Max	Wilcoxon	1,3592	Ascendente	1,94E-05
14	HR_T_Median	Wilcoxon	0,8037	Ascendente	3,34E-05
15	SCL_T_Skew	Paired t-test	-0,3252	Descendente	6,80E-05
16	HR_T_Skew	Wilcoxon	-0,0172	Descendente	9,72E-05
17	HR_T_Range	Wilcoxon	0,2313	Ascendente	0,0001
18	EDA_T_Std	Wilcoxon	0,0081	Ascendente	0,0003
19	SCL_T_Kurtosis	Wilcoxon	-0,2336	Descendente	0,0003
20	SCR_T_Max	Wilcoxon	0,0114	Ascendente	0,0009
21	EDA_PsdMax	Wilcoxon	0,0351	Ascendente	0,0014
22	EDA_T_Range	Wilcoxon	0,0253	Ascendente	0,0015
23	EDA_T_Pendiente	Wilcoxon	0,0142	Ascendente	0,0023
24	PPG1_T_Pendiente	Wilcoxon	-13,27	Descendente	0,0026
25	SCR_T_Std	Wilcoxon	0,0045	Ascendente	0,0030
26	EDA_PsdVar	Wilcoxon	0,0005	Ascendente	0,0034
27	SCR_T_Range	Wilcoxon	0,0173	Ascendente	0,0040
28	SCR_PeakCount	Wilcoxon	-0,6990	Descendente	0,0054
29	SCR_T_Pendiente	Wilcoxon	0,0085	Ascendente	0,0059
30	SCR_MeanPeakAmp	Wilcoxon	0,0063	Ascendente	0,0156
31	SCL_T_Std	Wilcoxon	0,0031	Ascendente	0,0161
32	PPG1_T_Range	Wilcoxon	33,06	Ascendente	0,0181
33	PPG1_T_Max	Wilcoxon	33,06	Ascendente	0,0181
34	SCL_T_Range	Wilcoxon	0,0090	Ascendente	0,0214
35	PPG1_T_Mean	Wilcoxon	-0,5371	Descendente	0,0216
36	PPG1_T_Skew	Wilcoxon	0,2418	Ascendente	0,0317
37	PPG1_T_Kurtosis	Wilcoxon	2,2547	Ascendente	0,0341
38	PPG1_T_Std	Wilcoxon	2,7490	Ascendente	0,0433
39	SCR_SumRiseTime	Wilcoxon	-0,1647	Descendente	0,0455

En la Tabla 5.5 se entrega el detalle del test utilizado por característica donde solamente una característica cumplió el supuesto para aplicar t-test pareado; la diferencia de las medias de los dos conjuntos comparados (ventanas previas y posteriores) para dimensionar la amplitud de la diferencia; la tendencia, si el cambio es ascendente o descendente y el p-valor, que valida la significancia estadística entregada por el test.

Se observa que los principales biomarcadores encontrados para los eventos estresores están relacionados con la señal EDA y sus derivadas, SCR y SCL cuya tendencia de sus características calculadas mayormente son ascendentes, lo que es concordante con lo analizado en la literatura (ver sección 2.5).

Además, se observan características de las señales PPG su derivado HR que muestran diferencias estadísticamente significativas. Por otro lado, ninguna de las métricas relacionadas a SKT (temperatura corporal) muestran diferencias en la ventana de 10 segundos previa y posterior al evento estresor.

Con estos resultados es posible considerar e incluir estas características calculadas en modelos de aprendizaje automático o en reglas de decisión para detectar estrés en la conducción.

### **5.6.3. Resultados pruebas estadísticas señales psicofisiológicas por evento**

Además del análisis general, presentado en la sección 5.6.2, se realiza una revisión de los eventos por separado cuyos resultados se encuentran en las tablas del anexo 8.1. De los eventos en la ruta analizados el evento TÚNEL y el evento SIN TRÁFICO no arrojaron características significativas lo que es concordante con la intuición que este tipo de situaciones en la conducción no generan estrés.

Se destaca que en los eventos repentinos en la ruta (ANIMAL, VEHÍCULO AVERIADO o BICICLETA) generan una mayor cantidad de biomarcadores como se puede observar en las tablas 8.1, 8.4 y 8.7 donde concuerda la aparición de métricas relacionadas a la señal EDA con tendencia ascendente. Esta propensión puede ser explicada y relacionada a las colisiones o posibles colisiones que algunos de los participantes protagonizaron en el simulador.

Para el evento MAYOR TRÁFICO, como se observa en la tabla 8.2 tiene como características significativas una cantidad menor, posiblemente porque tiene un impacto menor a un evento repentino, pero también relacionadas a la señal EDA.

También arrojan características significativas los eventos relacionados al estado del vehículo como los CAMBIO DE NIVELES, SIN FRENO y el PINCHAZO cuyos resultados se resumen en las Tablas 8.8, 8.5 y 8.6, respectivamente. En este caso se observa una gran activación para el evento pinchazo arrojando una cantidad mayor de características significativas al ser un evento repentino. Se destaca también la predominancia de las señales SCR y SCL coincidente con las características encontradas en el análisis general de eventos.

El evento cambio de niveles fue declarado durante la certificación como el evento menos percibido durante la conducción en el simulador por lo que las características que arrojan significancia, en particular la pendiente de la temperatura (SKT) a priori no se descarta pero tampoco se considera como un biomarcador preponderante para el estrés. En el caso del evento SIN FRENO sólo entrega un biomarcador, esto se explica porque el tiempo de registro del evento, es decir, cuando el instructor lo lanza puede no coincidir con el momento en que el conductor nota la falta de frenos.

En conclusión, se han encontrado biomarcadores relacionados a las señales EDA, SCR, SCL, PPG y HR útiles para analizar y detectar el efecto de un evento en el estrés del conductor. Estos se considerarán en el análisis del impacto las intervenciones sobre el conductor en la sección 6.

#### **5.6.4. Resultados pruebas estadísticas datos telemétricos del simulador**

De la misma manera como se han analizados las señales psicofisiológicas en ventanas de 10 segundos entorno a los eventos registrados, se estudia el cambio de las medidas de los datos telemétricos registrado por del simulador siguiendo el mismo método de análisis estadístico para medidas dependientes de la sección 5.6.2.

En este caso se calculan las características: **Mean, Std, Median, Min, Max, Range, Kurtosis, Skew, Pendiente** para cada una de las siguientes medidas telemétricas descritas en la sección 5.5.2. De este total de características telemétricas analizadas se obtiene el subconjunto de 8 métricas significativas que se presenta en la Tabla 5.6.

Tabla 5.6: Características telemétricas con significancia menor a 0.05 para todos los eventos

<b>N</b>	<b>Característica</b>	<b>Test</b>	<b>Dif.Media</b>	<b>Tendencia</b>	<b>p-valor</b>
1	Freno_T_Mean	Wilcoxon	0,0491	Ascendente	0,0002
2	Freno_T_Median	Wilcoxon	0,0606	Ascendente	0,0005
3	Freno_T_Max	Wilcoxon	0,0830	Ascendente	0,0011
4	Freno_T_Std	Wilcoxon	0,0289	Ascendente	0,0014
5	Vel_T_Pendiente	Wilcoxon	-4,0577	Descendente	0,0024
6	Freno_T_Range	Wilcoxon	0,0754	Ascendente	0,0039
7	Freno_T_Pendiente	Wilcoxon	0,0611	Ascendente	0,0213
8	Acelerador_T_Mean	Wilcoxon	-0,0155	Descendente	0,0381

De la Tabla 5.6 se observa la evidencia de que el uso del pedal de freno en sus métricas de promedio, mediana, máximo y desviación estándar aumentaron significativamente el enfrentarse a los eventos estresores, mientras que el acelerador y la aceleración (es decir, la pendiente de la velocidad) disminuyeron significativamente. Por supuesto, como reacción al evento y como medida de compensación al estrés.

Al realizar el análisis por eventos cuyos resultados se presentan en el anexo 8.2, se observa que los eventos TÚNEL, SIN TRÁFICO y CAMBIO DE NIVELES no generaron cambios significativos en las características telemétricas. Esto es consistente con los resultados anteriores y apoya lo discutido sobre los biomarcadores encontrados para el evento de cambio de niveles.

Por otro lado, los eventos VEHÍCULO AVERIADO y PINCHAZO (ver tablas 8.11 y 8.15) son los que presentan una mayor cantidad de características telemétricas con significancia de lo que se concluye que son eventos con mayor efecto estresor en el conductor debido a su reacción. Esto último es consistente con la gran cantidad de características psicofisiológicas que arroja dicho análisis. Con este último análisis, se valida el método para obtener biomarcadores para estrés en la conducción.

## **6. Análisis de intervenciones en conducción**

### **6.1. Uso de intervenciones**

Los sistemas de información en el automóvil son una preocupación particular en la ergonomía. La tecnología ha diseñado sistemas de asistencia en ruta como información de navegación en tiempo real con información del trayecto y algunos eventos con los que se pueda enfrentar el conductor más adelante. Los problemas de diseño relacionados a evitar las distracciones por estos sistemas y a minimizar la duración de la mirada que puede ser perjudicial para la seguridad del conductor se han abordado sin considerar los efectos directos en la fatiga, en el estrés y en la carga cognitiva del conductor [114].

En la mayoría de las circunstancias estos sistemas tienen efectos mínimos en la conducción, especialmente porque el aumento de la carga cognitiva y la desatención son compensadas con acciones como la reducción de la velocidad. Sin embargo, estos sistemas no abarcan los efectos intrínsecos del conductor ni los efectos extrínsecos de la tarea y del entorno que pueden detonar estados indeseados como la fatiga, el estrés sostenido o la saturación cognitiva, que son factores que ponen en riesgo el rendimiento y la seguridad de la conducción. Otro punto importante que es de especial cuidado es cómo se presenta la intervención para no generar efectos adversos mayores sobre el conductor. Por ejemplo, un sistema de difícil manejo puede provocar frustración, reacciones agresivas, y estrategias de afrontamiento riesgosas en conductores propensos al estrés [114].

Por este motivo, como se discutió en las secciones 2.8 y 2.9, es necesario considerar el modelo de interacción entre los estados psicofisiológicos durante la conducción para proponer medidas de mitigación de los efectos negativos de estos estados y aumentar la seguridad. Con este objetivo se busca diseñar un sistema de monitoreo inteligente que tenga en cuenta las demandas cognitivas de la conducción, los niveles de estrés y de fatiga al momento de presentar una intervención con el objetivo de disminuir los riesgos.

## **6.2. Criterios de selección de intervenciones**

Considerando las pautas propuestas por [114] para el diseño de intervenciones para el estrés y fatiga se presentan a continuación los criterios que se considerarán para la selección de intervenciones.

### **6.2.1. Reconocer cuál es el problema de seguridad que se necesita abordar**

No todos los problemas de seguridad asociados a la conducción son abordables mediante intervenciones del entorno. Por ejemplo, deficiencias en la higiene del sueño, los déficit relacionados al alcohol o las drogas o los déficit graves relacionados con la edad pueden requerir que la intervención sea directamente dejar de conducir. En cambio, problemas definidos como "transaccionales", es decir, donde los objetivos de seguridad entran en conflicto con los objetivos personales, como la reducción del esfuerzo en la tarea y la búsqueda de comodidad cuando aumenta la fatiga sí son posibles de abordar.

### **6.2.2. Distinguir las distintas reacciones al estrés y la fatiga**

Considerar las distintas reacciones al estrés de los individuos permite considerar patrones de comportamiento para centrar la intervención en el control del estrés 'en la marcha' previniendo la sobrecarga del operador. Por otro lado, las intervenciones para la fatiga deben promover la regulación del esfuerzo y la motivación de la tarea. El sistema debe evaluarse tanto en circunstancias estresantes como rutinarias.

### **6.2.3. Diseñar considerando la variabilidad de la carga cognitiva**

Los efectos del estrés y la fatiga en el rendimiento son sensibles a la demanda de la tarea. Se debe tener en cuenta la carga cognitiva propia de la tarea de conducción. También, considerar que la tecnología debe ser lo suficientemente fácil de usar para no sobrecargar al conductor ni generar preocupaciones que puedan distraerlo. El principal problema de diseño es minimizar la sobrecarga cognitiva de la intervención.

#### **6.2.4. Trabajar a nivel del individuo si es posible**

Las intervenciones a menudo serán más efectivas cuando estén dirigidas a conductores de manera individual pues es bien sabido que existen diferencias sustanciales entre la reacción a los eventos de la conducción para distintos conductores. Este criterio suele ser costoso en la investigación pues amplifica el número de evaluaciones que se deben realizar pero, con las consideraciones apropiadas de normalización de la tarea y los datos, el análisis grupal puede resultar en una excelente aproximación.

### **6.3. Intervenciones propuestas**

Aunque la tendencia general del uso de los sistemas de apoyo en la conducción es a aumentar la probabilidad de sobrecarga de recursos cognitivos esto depende también de la naturaleza del recurso requerido, según el modelo de recursos múltiples de Wickens explicado en la sección 2.4.2.

Por este motivo, en principio se catalogan las distintas opciones de intervenciones en 3 tipos: ópticas, acústicas y hápticas. A continuación, se presentan distintas intervenciones propuestas según su categoría.

#### **6.3.1. Ópticas**

En un estudio de laboratorio se encontró evidencia de que las pantallas de información en los automóviles pueden desviar la atención del entorno del tráfico [116]. Además, los sistemas de alerta pueden provocar evaluaciones negativas de los eventos y, en consecuencia, un aumento en el estrés de los conductores. Por este motivo, se aconseja expresar la advertencia a modo de instrucción, por ejemplo: usar 'reduzca la velocidad', en vez de 'está conduciendo demasiado rápido' puede resultar menos amenazante.

En un estudio se observó que la fatiga afectó la atención visual dirigida a los estímulos de las tareas secundarias durante la conducción. Por otro lado, en un segundo estudio llevado a cabo en un simulador se observó que instrucciones de desempeño en la pantalla moderaron la fatiga observada en el control del vehículo [114].

En otro estudio analizado se sugiere que las pantallas de alerta no críticas pueden aparecer atenuadas e ir reduciendo su visibilidad a medida que el conductor se aproxime a un evento que requiera mayor atención, como por ejemplo una intersección, para así reducir la probabilidad de distracción [115].

Algunos ejemplos de intervenciones ópticas del entorno son:

1. **Luz de alerta:** Luz intermitente de distinta intensidad activada en la pantalla del sistema de monitoreo.
2. **Notificación de texto:** Mensaje mostrado en la pantalla del sistema de monitoreo.

### 6.3.2. Acústicas

Algo importante a considerar es que la conducción es principalmente una tarea visomotora de atención sostenida. Se ha demostrado que las instrucciones de ruta durante la conducción en simulador tienen mejor resultado al ser presentadas de forma auditiva que visual disminuyendo la interferencia cognitiva. De todas maneras, la interferencia dependerá de las habilidades y experiencia del conductor [116].

Por otro lado, otro estudio demostró que, contrario a la hipótesis de recursos múltiples, una tarea de razonamiento auditivo genera mayor interferencia que una tarea de razonamiento visual en la conducción en simulador. Sin embargo, el mismo estudio sugiere que la conducción real genera el desarrollo de habilidades para compartir el recurso cognitivo de manera más eficiente [116].

En este aspecto, es interesante considerar los hallazgos encontrados por un estudio que sugiere que el humor puede atenuar las emociones negativas (por ejemplo, el estrés) como resultado de la distracción cognitiva que previene el procesamiento congruente del estado del ánimo al utilizar recursos cognitivos necesario para la resolución de incongruencias presentes en algún aspecto humorístico. Se concluye también que los estímulos que plantean mayores demandas cognitivas fueron más efectivos para regular las emociones negativas que los estímulos menos exigentes [164].

En el análisis de la literatura que relacionan el estrés con la música se observa que hay muchos estudios que indican que la música puede reducir los niveles de estrés y ansiedad, pero no existe una explicación explícita de cómo actúa sobre la alteración de los estados emocionales. En una gran cantidad de estudios revisados se encontraron efectos beneficiosos de la música relajante y de la música autoseleccionada, esto incluye la música favorita de la persona o una selección de una lista de géneros musicales [197].

A continuación, se mencionan algunos ejemplos de intervenciones acústicas propuestas:

1. **Música:** Temas musicales pre-seleccionados por el conductor. Se considera una selección indirecta mediante una encuesta previa de tres preguntas: (1) ¿Qué música prefiere para relajarse? (2) ¿Qué música prefiere para sentarse a estudiar o leer un libro? (3) Seleccione 3 grupos de música o canciones favoritas.
2. **Alarma sonora:** Reproducción de timbre de distintos tonos y volúmenes.
3. **Notificación por voz:** Reproducción de mensaje de audio pre-grabado con mensaje de alerta.
4. **Chiste por voz:** Reproducción de chistes pre-grabados.

### 6.3.3. Hápticas

En un estudio de detección de fatiga en conductores mediante análisis del cierre de los ojos y la frecuencia del parpadeo se incorpora una chaqueta háptica para proporcionar la advertencia al conductor del estado de fatiga. Se toma la consideración de usar frecuencias de vibraciones semejantes a las de los celulares pues es un tipo de vibración familiar para la mayoría de los conductores y además, en lugar de usar vibraciones fuertes y repentinas se aplican aumentando progresivamente la intensidad para evitar sorprender o asustar. En este experimento se consideran tres niveles de alerta para tres niveles de fatiga detectados. Se selecciona tres áreas para aplicar las vibraciones: el área de los hombros para alertas leves, el pecho para alertas de nivel medio y la zona de la columna para alertas graves [141].

Por otro lado, otro estudio sobre fatiga en conducción realizado argumenta que las vibraciones como método de alerta para el conductor tiene limitaciones como que: (1) tienden a perder gradualmente su efectividad a medida que se repiten, (2) si es demasiado leve puede pasarse por alto debido a las vibraciones propias de la conducción como una calzada irregular o las vibraciones del motor y (3) si son demasiado intensas pueden generar molestias, incomodidad o dolor; propone una intervención háptica distinta. La contramedida propuesta es una guía háptica en el volante que ayuda al conductor a tomar el control del vehículo para mantener la línea central del carril. Este sistema fue probado con buenos resultados con 12 participantes en un simulador de conducción [185].

Adicionalmente, se han realizado investigaciones para relacionar los efectos de la temperatura ambiente y el desempeño humano. Una de ellas buscó comparar el rendimiento en la conducción considerando dos parámetros: la variabilidad de la posición dentro del carril y la variabilidad de la velocidad; con tres rangos de temperatura ambiente: baja (11 a 16 grados Celsius), media (16 a 21 grados) y alta (22 a 27 grados). Aunque el estudio no encontró significancia con la variabilidad de la posición del carril, sí se encontró un efecto significativo entre la temperatura alta sobre la variabilidad de la velocidad en comparación con las temperaturas medias y bajas [33].

En un estudio donde se evaluó el impacto de las condiciones climáticas sobre la fatiga laboral en conductores profesionales se encontró que tanto en una ruta monótona fuera de la ciudad como en una ruta de tráfico pesado en el centro de la ciudad existe una correlación entre la fatiga, el parpadeo frecuente, el cansancio y la dificultad para tomar decisiones con la temperatura ambiente [109].

Por lo tanto, las intervenciones hápticas propuestas son:

1. **Sistema vibrador:** Ubicado en el asiento o alguna parte del cuerpo del conductor.
2. **Termorregulación:** Activación/desactivación de aire acondicionado de la cabina del vehículo.

## 6.4. Diseño experimental de validación de intervenciones

En esta sección se detalla el diseño experimental llevado a cabo para la validación de intervenciones del entorno de conducción en un ambiente real. Se describe el grupo de participantes, las intervenciones seleccionadas, los aparatos, la tarea y ruta junto con el protocolo experimental.

### 6.4.1. Participantes

Se escoge una muestra por conveniencia de 14 participantes con un promedio de  $32,3 \pm 9,6$  años de edad donde 8 son hombres y 6 mujeres. Dos declaran tener menos de un año de experiencia en conducción, cuatro entre 1 y 5 años, dos entre 5 y 10 años y seis más de 10 años de experiencia.

El reclutamiento se llevó a cabo mediante la plataforma u-cursos disponible para la comunidad universitaria de la Universidad de Chile. Los requisitos de inscripción al experimento fueron manejar un vehículo propio, tener licencia de conducir clase B al día y estar familiarizado con el asistente de navegación Google Maps. Además, se consideró como incentivo un apoyo económico a la investigación por un monto de 15 mil pesos para cada voluntario.

Cada voluntario completó la tarea utilizando los aparatos de medición, firmando un consentimiento informado, respondiendo cuestionarios y encuestas al iniciar y finalizar la tarea de conducción.

La encuesta inicial contenía consultas sobre información demográfica, información de salud y calidad del sueño durante la noche previa al experimento. Además, se consulta sobre la dificultad y las intervenciones percibidas. En la Tabla 6.1 se muestra el resumen de la esta encuesta.

Tabla 6.1: Resumen de encuesta experimento de intervenciones

Edad	Comorbilidad	Durmió bien	Horas de sueño	Dificultad percibida
32,3 (9,6)	4/14	11/14	6,5 (1,0)	5,8 (1,3)

En la encuesta final se consulta sobre la dificultad y las intervenciones percibidas. En la siguiente sección se profundiza sobre esto.

#### 6.4.2. Intervenciones seleccionadas

Se debe tener en cuenta que probar todas las intervenciones propuestas requeriría una gran cantidad de datos para darle la debida validez estadística, lo cual, dado el número limitado de conductores, resulta infactible. Por este motivo se seleccionará un subconjunto de intervenciones a implementar y validar. Se escoge una de tipo auditiva y una de tipo háptica. Se descarta a priori la de tipo visual porque al ser la conducción una tarea de atención sostenida es más probable que ante una intervención visual los recursos cognitivos compitan y que la carga mental aumente.

La intervención de tipo auditiva corresponde a un audio reproducido en un smartphone cuya duración es de aproximadamente 7 segundos con una voz masculina en español y con emoción neutra que menciona la frase: "Oye, parece que estás algo estresado. Respirar tres veces puede ayudar a relajarte".

La intervención háptica se activa en una pulsera en la muñeca derecha del conductor. Esta genera una alerta de vibración similar a la de los smartphone durante 20 segundos.

A cada conductor se le presenta sólo un tipo de intervención (existen 8 auditivas y 6 hápticas). Estas intervenciones aparecen cada 15 minutos con un margen de más/menos 2 minutos para disminuir sesgos. Considerando una ruta de aproximadamente 3 horas se aplicarán un total de 12 veces cada intervención por tarea.

Al finalizar el experimento se realiza una encuesta a cada participantes respecto a su percepción de cada intervención, su efecto y además la dificultad percibida de la tarea en general. El resumen de esta encuesta se presenta en la Tabla 6.2.

Tabla 6.2: Resumen de encuesta de percepción de intervenciones

<b>Tipo</b>	<b>Part.</b>	<b>Ejecutados</b>	<b>Percibidos</b>	<b>Sensación</b>
Auditiva	8	13,1 (2,6)	7 (2,6)	3 Bien/5 Indiferente/o Mal
Háptica	6	12,8 (2,5)	6,5 (2,1)	0 Bien/4 Indiferente/2 Mal

### **6.4.3. Tarea**

El conductor debe seguir las instrucciones del asistente de navegación hasta completar la ruta predeterminada entregada por el experimentador. El conductor tiene completamente prohibido interactuar con la radio (que estará apagada) ni con los aparatos de medición e intervención del entorno hasta completar la tarea.

Cada dos intervenciones y en un tiempo aleatorizado se realiza una encuesta a través de un audio que deben responder a viva voz de autoreporte de fatiga KSS (Karolinska Sleepiness Scale) en una escala de Likert de 1 (extremadamente alerta) a 9 (Muy somnoliento). La pregunta se realiza con una voz femenina, en español y con emoción neutral, diciendo: "Atención, vamos a hacer un par de preguntas ¿Cómo se siente en la escala de 1 a 9? donde 1 corresponde a extremadamente alerta y 9 somnoliento. Su respuesta, por favor."

Además, se pregunta: "¿Cuál de las siguientes emociones lo identifican en este momento? contento, relajado, aburrido o estresado. Su respuesta, por favor." Con esto se busca etiquetar con una emoción específica ese momento de la conducción. Estas emociones se escogieron como representativas de cada cuadrante del modelo de emociones circumplex [148].

### **6.4.4. Definición de ruta**

Mediante la aplicación de Google Maps se traza la ruta que debe seguir cada participante, pudiéndose guiar con el asistente de navegación desde su smartphone. Es una ruta por Santiago de aproximadamente 70 km y se estima unas tres horas de conducción, en horario de tráfico normal. Mediante una aplicación de rastreo se obtienen los datos GPS y el tiempo de recorrido en cada experimento desarrollado.

En la Figura 6.1 se muestra la ruta definida para la experimentación. Esta comprende tramos con distintas características para diversificar la conducción: tramos por caletería, por calles en uno y doble sentido, pasos bajo nivel, rotondas, avenidas principales, zonas de tráfico denso y de tráfico liviano. La ruta puede consultarse en el siguiente link: <https://goo.gl/maps/juXrpomAqk9moUNA8>.

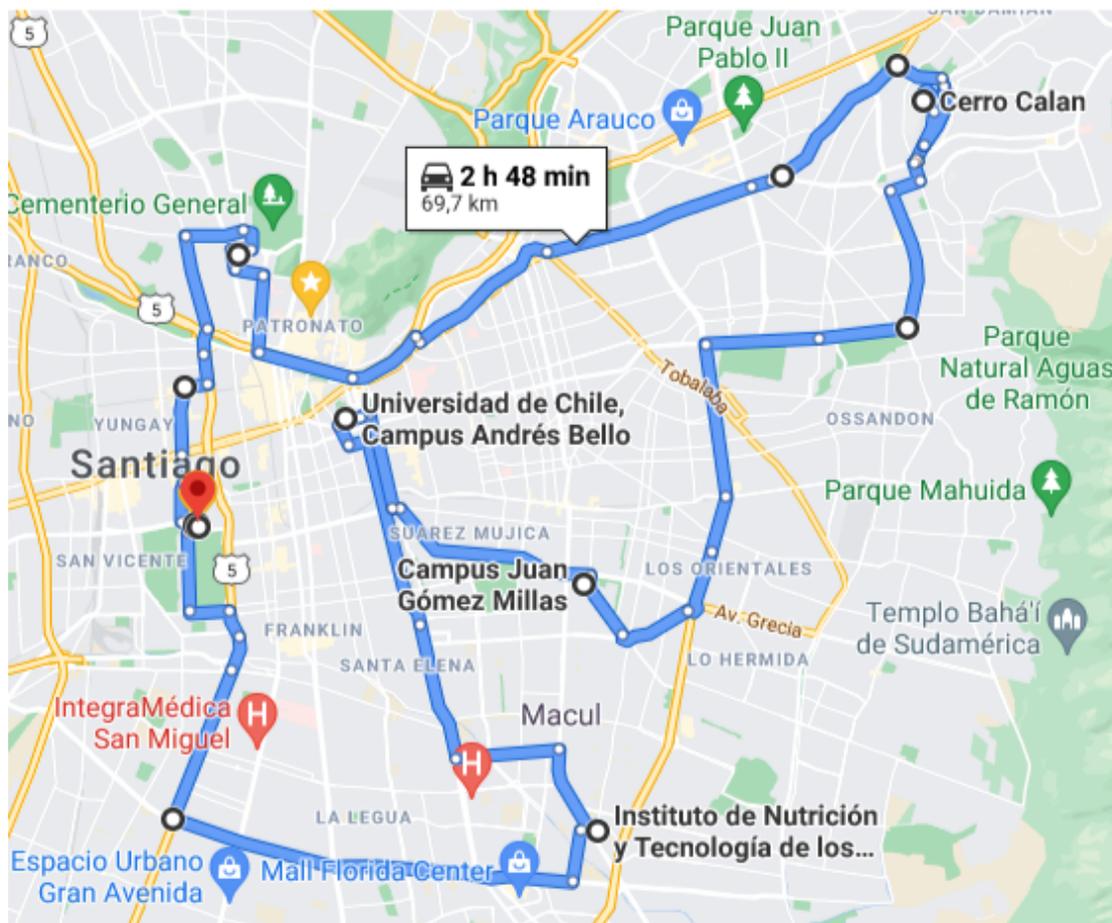


Figura 6.1: Ruta por Santiago para validación de intervenciones

#### 6.4.5. Aparatos y montaje

Los participantes conducen siguiendo la ruta definida utilizando la pulsera BioMonitor V2.0 en la muñeca izquierda para capturar señales psicofisiológicas en tiempo real junto con el kit de sensor de variables de contexto en la cabina, sensores explicados en la sección 3.2.

Además, se dispone de una cámara en el panel del vehículo que graba frontalmente a cada participante para posteriormente analizar conductas durante el manejo, especialmente las relacionadas a fatiga.

Se agrega una dashcam posicionada en el parabrisas que graba continuamente hacia la calle mientras el vehículo está en movimiento para obtener un registro visual de algún evento. Un esquema del montaje de estos sensores se muestra en la Figura 6.2.

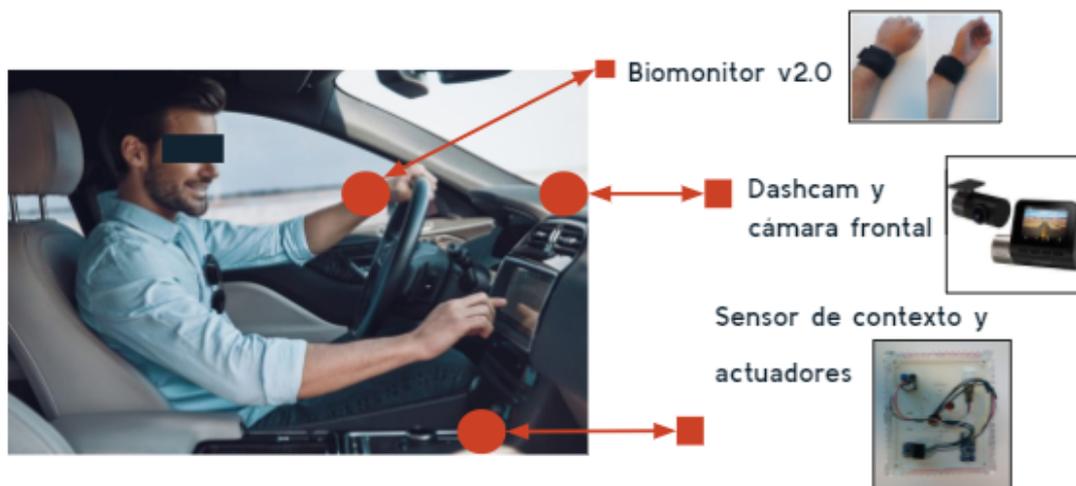


Figura 6.2: Montaje de aparatos experimento validación de intervenciones

Se busca que los dispositivos encargados de ejecutar las intervenciones, también llamados actuadores, interfieran lo menos posible en la conducción. En el caso de la intervención auditiva se activa en un smartphone específico para el experimento que además registra el GPS.

El actuador háptico es una pulsera deportiva utilizada por el conductor en la mano derecha que es programada para ejecutar la vibración. En la Figura 6.3 se muestra la pulsera vibratoria utilizada en los experimentos.



Figura 6.3: Pulsera vibratoria

#### **6.4.6. Protocolo experimental**

Antes y después del experimento se debe realizar el mismo protocolo que el presentado en la sección 5.4.5. Tomando en consideración la validación de las intervenciones, a continuación se detalla el ajuste de los pasos durante el experimento.

##### **Antes del experimento**

1. Experimentador se presenta en el punto de inicio de la ruta con baterías cargadas y todos los dispositivos y aplicaciones dispuestas para una actividad experimental fluida.
2. Dar la bienvenida y la descripción general del experimento y asegurar la firma del consentimiento informado.
3. Rellenar formulario de datos demográficos y situación de salud del participante.
4. Instalar y validar funcionamiento de cámaras para el registro visual de la cara del conductor y hacia la calle.
5. Instalar y validar funcionamiento del sensor de contexto dentro de la cabina del conductor.
6. Instalar sensores al participante. Verificar la comodidad y funcionamiento.
7. En smartphone del experimento: iniciar GPS, programar intervenciones y audio de encuesta de autorreporte.
8. Sincronizar los tiempos de captura de la pulsera, sensor de contexto, smartphone del experimento y cámara.
9. Registrar línea base de las señales del participante. Etapa de medición de 3 minutos sin estímulos en posición relajada sentado dentro del vehículo estacionado.
10. Entregar ruta al participante, dar últimas indicaciones y responder posibles dudas.
11. Dar inicio al experimento.

### **Durante el experimento**

1. Supervisar remotamente el funcionamiento y correcta medición de los sensores, durante todo el experimento.
2. Estar atento para dar cualquier asistencia al conductor mientras se encuentra en ruta.
3. Dar por finalizado el experimento cuando el participante termine la tarea al completar la ruta establecida.

### **Después del experimento**

1. Indicar término de la actividad.
2. Detener y retirar los sensores. Se finaliza la toma de datos.
3. Preguntar y reportar cualquier situación relevante para el análisis posterior (situación anómala o incómoda, mareos, estrés, sueño, etc.).
4. Rellenar encuesta de percepción de intervenciones durante la conducción.
5. Despedida del participante, agradecimiento por participación y pago de incentivo monetario.
6. Descargar y almacenar debidamente los archivos de los distintos sensores.

## **6.5. Datos capturados**

Para completar el tamaño de 14 participantes según la muestra por conveniencia definida se realizaron un total 18 experimentos de los cuales debieron descartarse uno por problemas de sincronización de los datos, dos por pérdida de datos y uno porque el participante no pudo completar la ruta.

También existieron pérdidas de datos dentro de los participantes seleccionados. El resumen de los datos capturados se presenta en la Tabla 6.3 donde se presenta la cantidad de intervenciones programadas según su tipo y cuántas de esas intervenciones tienen datos suficientes para su análisis con las señales capturadas con la pulsera Biomontor, datos de contexto y capturas de la cámara frontal. Estas serán el total de muestras a analizar, por sensor, para comparar el impacto de las intervenciones seleccionadas.

Tabla 6.3: Resumen de datos capturador en experimento de intervenciones

Tipo	Programados	Biomonitor	Contexto	Cámara
Auditiva	100	75	66	83
Háptica	67	58	60	57

En el histograma de la Figura 6.4 se muestra de manera disgregada por participante esta información, en verde se marcan los participantes que recibieron una intervención auditiva (P2, P4, P7, P12, P14, P16, P17, P18) y en naranja la intervención háptica (P3, P6, P8, P9, P13, P15).

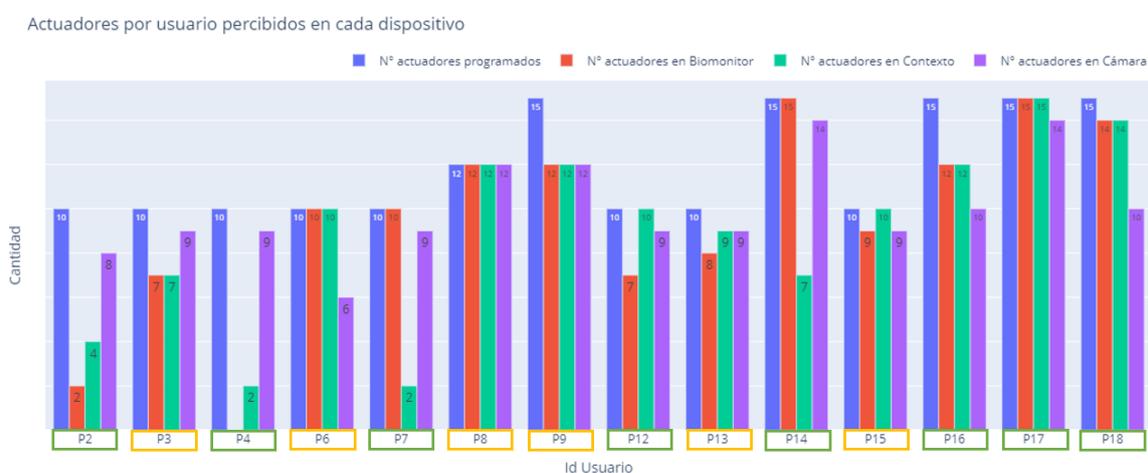


Figura 6.4: Histograma de datos correctamente capturados en experimento de intervenciones

### 6.5.1. Datos de autorreporte

A continuación se presenta el resumen de los datos capturados en la encuesta de autorreporte consultada durante la conducción. En algunos casos no se pudo recuperar la respuesta. Dos de los participantes alcanzaron a responder el séptimo KSS porque les tomó más tiempo completar la ruta. En la Tabla 6.4 se muestra el resumen con el promedio, la desviación estándar y la cantidad de respuestas obtenidas a lo largo del experimento.

Para estos datos se calcula el alfa de Cronbach, un índice usado para medir la confiabilidad del tipo consistencia interna de una escala. El resultado arroja un valor de 0,81 lo que indica una alta confiabilidad de los resultados de este instrumento.

Tabla 6.4: Resumen KSS en experimento de intervenciones

	KSS-1	KSS-2	KSS-3	KSS-4	KSS-5	KSS-6	KSS-7
<b>Promedio</b>	3,4	3,4	4,4	3,9	4,4	4,9	4,5
<b>Desv. Estándar</b>	1,1	1,8	1,6	1,5	1,6	1,7	2,1
<b>Cantidad</b>	14	13	12	11	10	7	2

Además, en el gráfico de la Figura 6.5 se observa la tendencia creciente de la fatiga/somnolencia declarada en el KSS para el promedio de todos los participantes con un modelo lineal que tiene un muy buen ajuste de  $R^2 = 0,7108$ .

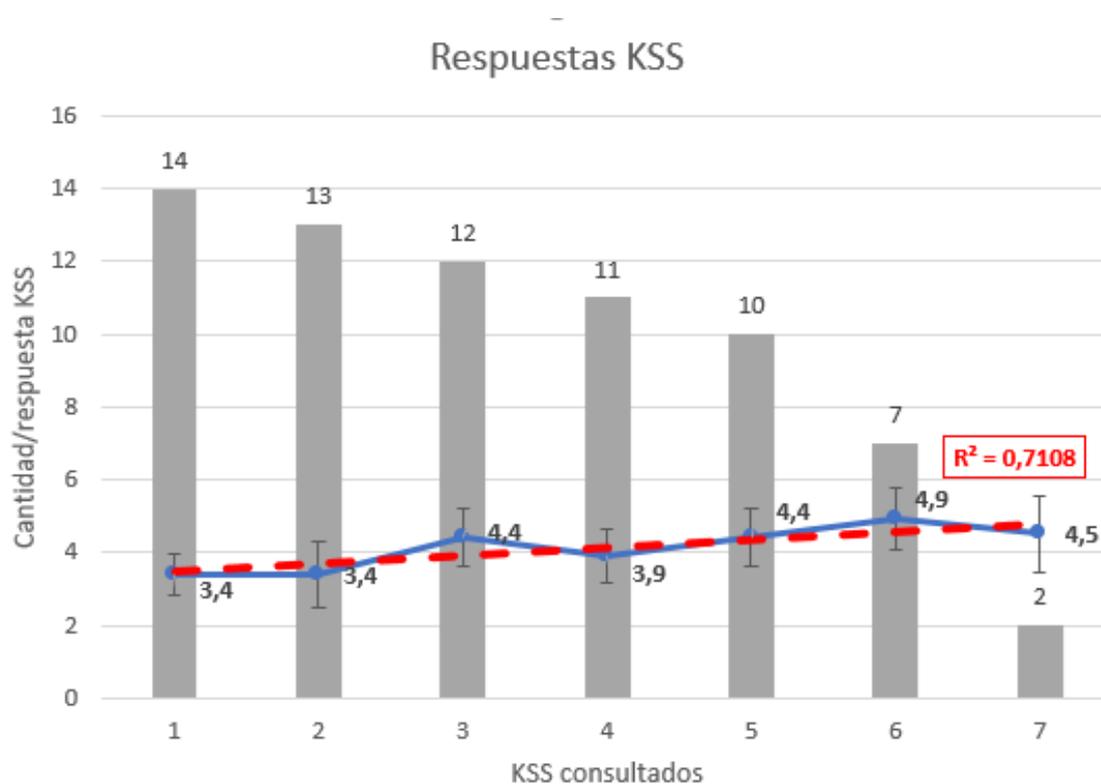


Figura 6.5: Histograma de respuestas de KSS

También se analizan las respuestas a las cuatro emociones declaradas. En la Tabla 6.5 se puede observar la evolución de la emoción autopercebidas. Se puede ver que la tarea no genera felicidad pues la mayoría parte relajado y termina o aburrido o estresado.

Si hacemos un análisis sólo considerando hasta la quinta respuesta (E5), que es hasta donde casi todos contestaron, el aburrimiento aumenta y el estrés se mantiene constante, mientras que la relajación disminuye.

Tabla 6.5: Resumen emociones declaradas en experimento de intervenciones

	<b>E1</b>	<b>E2</b>	<b>E3</b>	<b>E4</b>	<b>E5</b>	<b>E6</b>	<b>E7</b>	<b>Total</b>
<b>Aburrido</b>	2	4	5	4	7	2	0	<b>24</b>
<b>Contento</b>	0	0	2	2	0	1	0	<b>5</b>
<b>Estresado</b>	4	5	2	3	3	4	2	<b>23</b>
<b>Relajado</b>	8	4	3	2	0	0	0	<b>17</b>

### 6.5.2. Datos de captura de videos

Los datos audiovisuales de cada individuo permiten observar su comportamiento dentro del vehículo. Las personas al momento de conducir realizan diferentes acciones y gesticulan de acuerdo a factores internos como, por ejemplo, el cansancio u otros estados emocionales. También, los gestos pueden ser desencadenados en algunos casos por factores externos como, por ejemplo, al encontrarse con situaciones inesperadas o peligros que pueden originar accidentes de tránsito. En esta sección se explica en particular el uso de videos del rostro del conductor en relación al estado de fatiga.

En la literatura se han estudiado gestos representativos de fatiga de un individuo. Por ejemplo, en [98] se relacionan los bostezos como característicos de la fatiga. En [132] se ha estudiado que la forma de los pestañeos y cómo estos se diferencian en situaciones normales y situaciones de fatiga. Finalmente, para una ventana de tiempo representada en un video, existe la métrica “percentage of eyelid closure” (PERCLOS) [40] que se calcula según la ecuación (1), donde  $E_c$  es la cantidad de frames con los ojos cerrados a un 80 % o más, y  $E_o$  la cantidad de frames con ojos abiertos. De esta manera un PERCLOS mayor para una ventana de tiempo, indicaría somnolencia o fatiga por parte del conductor, ya que posee menor capacidad de mantener los ojos abiertos. Es interesante notar que esta métrica solo puede ser calculada en situaciones donde  $E_c + E_o > 0$ , es decir, cuando es posible detectar los ojos en el video.

$$PERCLOS = \frac{E_c}{E_c + E_o} \cdot 100 \% \quad (1)$$



Figura 6.6: Detección de rostro del conductor - Vista frontal



Figura 6.7: Detección de rostro del conductor - Vista lateral (derecha)

En estricto rigor es posible analizar cada frame de un video para detectar el tamaño de la apertura de los ojos, si es que la persona ejerce algún pestañeo, o si bosteza. Sin embargo, para grandes volúmenes de datos, es decir, una gran cantidad de frames por usuario y una gran cantidad de usuarios, hacer este proceso manualmente se vuelve infactible. Por lo tanto, se necesitan métodos automatizados para realizar el cálculo de estas métricas, que sean útiles dentro del ambiente de conducción.

El comportamiento de los conductores es altamente variable, lo que presenta algunos impedimentos para aplicar métodos automatizados de detección de parpadeos y bostezos con alta fidelidad a partir de imágenes. La existencia de una gran cantidad de movimientos de cabeza realizados por el individuo (no siempre el gesto a detectar se realiza de frente a la cámara), vibración del vehículo (creando diferencias en las coordenadas frame a frame), gestos similares como cantar, toser, balbucear (que pueden resultar en falsos positivos), entre otros, dificultan este proceso. Dado esto, para este estudio, la detección de bostezos en ruta con alta confiabilidad se realiza de manera manual, dejando propuesto el desarrollo de métodos automatizados para trabajo futuro. La detección de pestañeos y PERCLOS en cambio se desarrolla de manera automatizada.

Se utilizan métodos de detección ocular para calcular la métrica de PERCLOS y cantidad de pestañeos. Utilizando inteligencia artificial, en particular un modelo entrenado de la librería MediaPipe [119], es posible la detección del rostro del conductor en cada frame de un video (ver figuras 6.6 y 6.7).

A través de una malla facial computarizada en cada frame se logra calcular la apertura vertical y la distancia horizontal de los párpados (ver figura 6.8). Dado que estos valores dependen de la distancia del sujeto a la cámara, es decir, entre más lejos menor serán los valores, se utiliza la métrica conocida como “Eye Aspect Ratio” (EAR) [26], que se calcula como  $D_v/2D_h$  donde  $D_v$  es la distancia vertical y  $D_h$  la distancia horizontal.

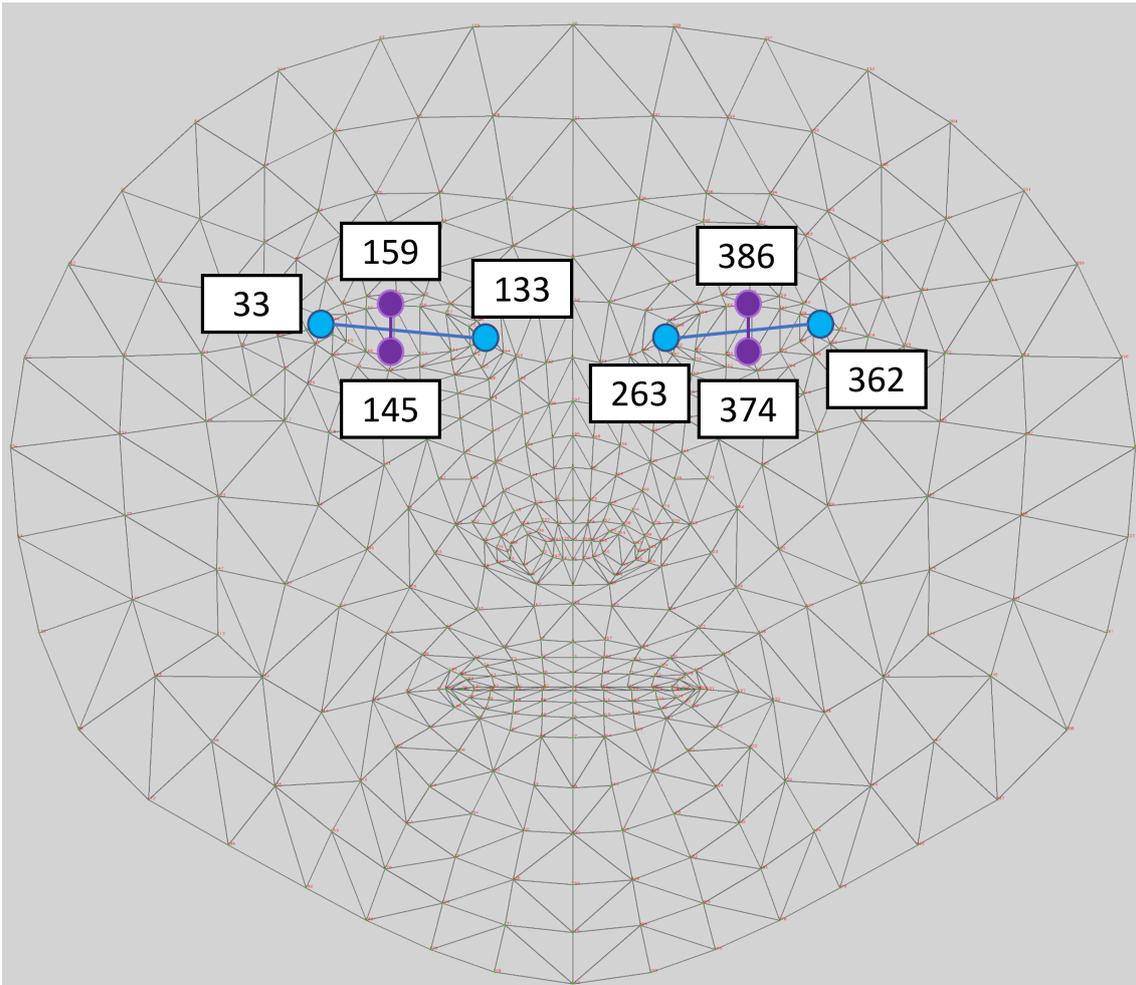


Figura 6.8: Malla facial, puntos para calcular las distancias.

Calculando el EAR para una ventana de tiempo de 1 minuto, se observan peaks en los momentos que el usuario gira la cabeza y se pierde la información de un ojo (figura 6.9). Por ejemplo, en la figura 6.7 el usuario gira su cabeza hacia la derecha, por lo cual el ojo derecho no se ve en la grabación, presentándose un peak en la señal. Los cuantiles de 90 % de datos para cada ojo no calzan en un mismo valor ya que ningún rostro es simétrico, por lo que se usan separadamente para cada señal para eliminación de outliers (figura 6.10).

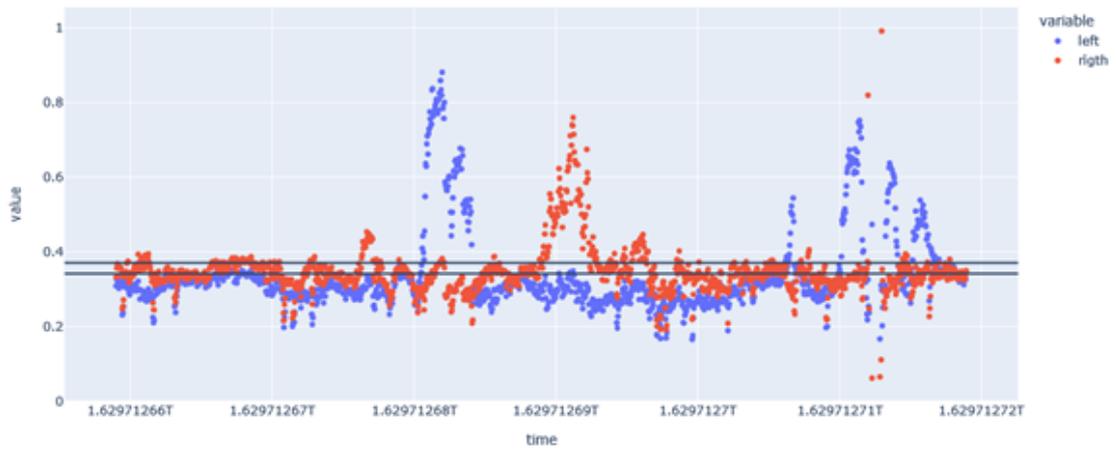


Figura 6.9: EAR calculado para ambos ojos en ventana de tiempo de 1 minuto. Líneas horizontales negras corresponden a los cuantiles de 90 %.

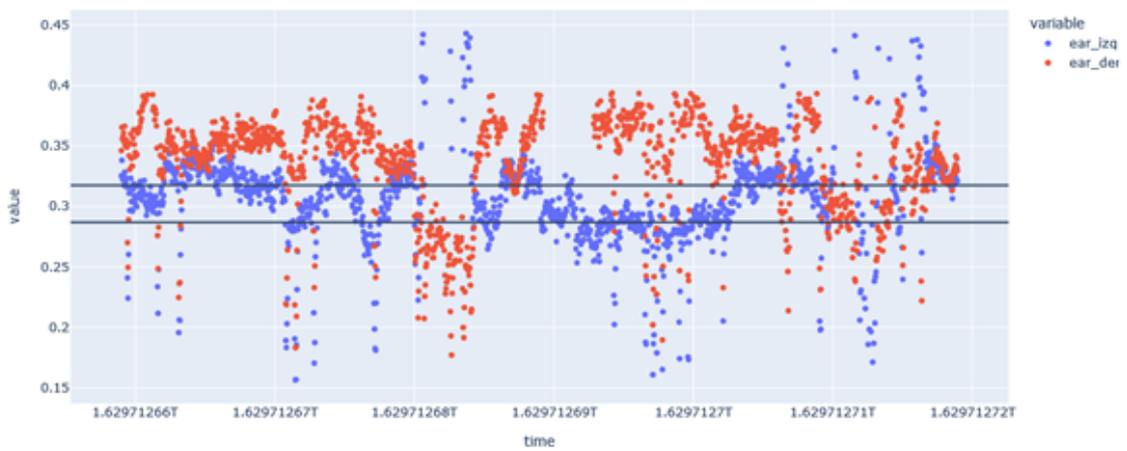


Figura 6.10: EAR calculado para ambos ojos en ventana de tiempo de 1 minuto con eliminación de outliers.

Se hace una detección de la posición de la cabeza del conductor mediante la librería Open CV y el método solvePnP [133]. Para ello se toma el punto central de la cara, es decir, la punta de la nariz para determinar el punto 3D que proyecta dicho punto 2D dentro de la imagen. Esto genera una señal de coordenadas  $x$  a la cual, utilizando los cuantiles de 20 % y 80 % que se obtienen, se le puede asignar la dirección de la cabeza a la derecha si es que el punto se encuentra con valores bajo el 20 % de los datos e izquierda si se encuentra sobre el 80 % (dado el efecto reflejo de la cámara). Estos cuantiles deben calcularse sobre la grabación de toda una sesión de conducción, ya que se opera bajo el supuesto que en una sesión larga el conductor tenderá a mantener una posición frontal con ligeras desviaciones.

Esta hipótesis se valida en los datos utilizados en este estudio, comprobando una correcta detección de la dirección de la cabeza en diferentes ejemplos, como los mostrados en las figuras 6.6 y 6.7. Finalmente, conociendo la apertura de cada ojo y la posición rotacional de su cabeza, es posible la detección de pestañeos y el cálculo del PERCLOS.

Para calcular los pestañeos, se aplica un algoritmo iterativo sobre las señales EAR de cada ojo, y de la señal promedio de ojo izquierdo y derecho, en el cual se detectan peaks negativos menores a un umbral en una cantidad mínima determinada de frames sucesivos. Los peaks finales a considerar corresponden a los capturados por el ojo derecho en los momentos donde la rotación de la cabeza se realiza hacia la izquierda, a los del ojo izquierdo, al momento en que la rotación de la cabeza es hacia el lado derecho, y los de la señal promedio en los momentos en que la persona mira de frente. En la figura 6.11 se observa la señal promedio y los pestañeos detectados.

Para el cálculo del PERCLOS dentro del video de una ventana de tiempo se consideran el EAR del ojo derecho, izquierdo o de la señal promedio según la rotación de la cabeza, siguiendo la misma lógica que para el caso de los pestañeos. Para  $E_c$  se consideran los casos en que el EAR es menor al cuantil 15 % del usuario, y para  $E_o$  los casos mayores, permitiendo el cálculo de la ecuación 1.

La detección de bostezos se hace mediante análisis visual de todos los vídeos para detectar en qué momento empiezan y terminan.

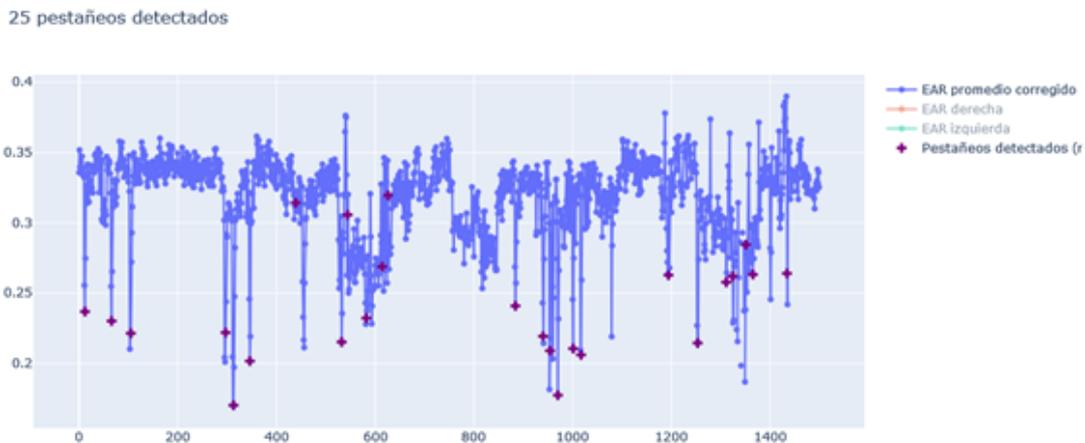


Figura 6.11: Señal EAR promedio y pestañeos detectados por el algoritmo.

Con todo los datos anteriormente explicados, para una ventana de tiempo dada, se calculan las distintas características propias de la fatiga como: el número de bostezo, la duración promedio de los bostezos y su desviación estándar, la cantidad de pestañeos, PERCLOS y estadísticas EAR de cada ojo y de la señal promedio (Promedio, desviación estándar, mínimo y máximo).

## 6.6. Análisis y resultados

Con los datos consolidados, validados y procesados se realizan distintos análisis estadísticos para observar el efecto de las intervenciones estudiadas: háptica y auditiva, sobre los estados psicofisiológicos: fatiga y estrés. Con estos análisis se desea encontrar indicadores propios de cada estado psicofisiológico que muestren un cambio estadísticamente significativo tras aplicar la intervención y verificar si este cambio es positivo o negativo, es decir, si verdaderamente la intervención tiene un efecto en atenuar el estado de estrés y/o fatiga.

Como estudio adicional se analiza el efecto de las variables de contexto y ambientales en los estados psicofisiológicos de fatiga autorreportada y estrés, este último observado mediante el autorreporte de emociones (ver Tabla 6.5).

### 6.6.1. Análisis de efecto de intervención háptica sobre fatiga

Para estudiar el efecto de las intervenciones sobre la fatiga se analizaron características típicas de este estado, tales como: frecuencia de pestaños, cantidad y duración de bostezos y los indicadores PERCLOS y EAR descritos en la sección 6.5.2; obtenidos del procesamiento de los datos audiovisuales disponibles.

A cada característica calculada se le aplica un test T-pareado o Test Wilcoxon dependiendo si cumple o no los supuestos para el uso de estos test. Se comparan la ventana de tiempo previa y la ventana de tiempo posterior a la activación de cada intervención. Se estudian ventanas de tamaños de 5 y 10 minutos considerando el efecto acumulativo de la fatiga.

Los resultados obtenidos de los test estadísticos para la intervención háptica se presentan en las tablas 6.8 y 6.9. De estos se observa que no hay evidencia que demuestre que la intervención háptica tenga un efecto en la disminución o atenuación del aumento de la fatiga ni en la aparición de las características relacionadas a ella como la cantidad de pestaños y la cantidad y duración de los bostezos, esto tanto para ventanas de 5 como de 10 minutos.

Tabla 6.6: Características de fatiga con significancia menor a 0.1 para intervención háptica en ventanas de 5 mins

N	Característica	Test	Dif.Media	Tendencia	p-valor
1	n_blinks	Wilcoxon	101,1132	Ascendente	2,36E-05
2	n_bostezos	Wilcoxon	0,1509	Ascendente	0,0042
3	max_dur_bos	Wilcoxon	554,6981	Ascendente	0,0217
4	std_dur_bos	Wilcoxon	19,2547	Ascendente	0,0280
5	mean_dur_bos	Wilcoxon	535,4434	Ascendente	0,0395

Tabla 6.7: Características de fatiga con significancia menor a 0.1 para intervención háptica en ventanas de 10 mins

N	Característica	Test	Dif.Media	Tendencia	p-valor
1	n_blinks	Wilcoxon	36,24	Ascendente	0,0008
2	std_dur_bos	Wilcoxon	228,10	Ascendente	0,0107
3	n_bostezos	Wilcoxon	0,3333	Ascendente	0,0223
4	max_dur_bos	Wilcoxon	842,24	Ascendente	0,0355
5	mean_dur_bos	Wilcoxon	592,25	Ascendente	0,0626

Conclusión: La intervención háptica no fue capaz de contrarrestar el aumento de la fatiga en el tiempo. Esto no significa que la intervención háptica esté provocando fatiga. Sin embargo, tampoco se puede concluir que esté morigerando el aumento de esta.

### 6.6.2. Análisis de efecto de intervención auditiva sobre fatiga

De la misma manera, se aplican los test estadísticos a las características relacionadas con la fatiga para analizar la intervención auditiva comparando la ventana previa y posterior, también en ventanas de 5 y 10 minutos.

Los resultados obtenidos de los test estadísticos para la intervención auditiva se presentan en las tablas 6.8 y 6.9. De éstos se observa que para ventanas de 5 minutos no existe evidencia de que la intervención auditiva tenga efectos en la fatiga.

Sin embargo, para la ventana de 10 minutos se encuentra que existen signos de fatiga, como la duración de los bostezos, que disminuyen significativamente. Por lo tanto, hay evidencia que muestra una disminución de los signos de fatiga, somnolencia o cansancio y no hay indicadores de lo contrario para la intervención auditiva.

Tabla 6.8: Características de fatiga con significancia menor a 0.1 para intervención auditiva en ventanas de 5 mins

<b>N</b>	<b>Característica</b>	<b>Test</b>	<b>Dif.Media</b>	<b>Tendencia</b>	<b>p-valor</b>
1	n_blinks	Wilcoxon	28,0811	Ascendente	2,58E-05

Tabla 6.9: Características de fatiga con significancia menor a 0.1 para intervención auditiva en ventanas de 10 mins

<b>N</b>	<b>Característica</b>	<b>Test</b>	<b>Dif.Media</b>	<b>Tendencia</b>	<b>p-valor</b>
1	n_blinks	Wilcoxon	27,69	Ascendente	0,0041
2	min_dur_bos	Wilcoxon	-737,78	Descendente	0,0333
3	mean_dur_bos	Wilcoxon	-694,13	Descendente	0,0513
4	max_dur_bos	Wilcoxon	-623,90	Descendente	0,0873

### 6.6.3. Análisis de efecto de intervención háptica sobre estrés

Por otro lado, para estudiar el efecto de las intervenciones sobre el estrés se analizan características psicofisiológicas o biomarcadores según lo encontrado en el análisis de la sección 5.6, principalmente indicadores de presencia de estrés como el aumento del HR o de las señales EDA, SCR y SCL.

Tal como en la sección 5.6, a cada característica se le aplica un test T-pareado o Test Wilcoxon dependiendo si cumple o no los supuestos para el uso de estos test. Se comparan la ventana de tiempo previa y la ventana de tiempo posterior a la activación de cada intervención considerando un tamaño de 10 segundos.

Los resultados obtenidos de los test estadísticos para la intervención háptica se presentan en la tabla 6.10. De estos se observa que existe evidencia del aumento significativo del estrés, reflejado en el aumento del arousal durante los 10 segundos posteriores a la activación de la intervención háptica. Por lo tanto, esta intervención no fue capaz de contrarrestar los factores que están aumentando el estrés como eventos en la ruta, entre otros.

Tabla 6.10: Características psicofisiológicas con significancia menor a 0.05 para intervención háptica

<b>N</b>	<b>Característica</b>	<b>Test</b>	<b>Dif.Media</b>	<b>Tendencia</b>	<b>p-valor</b>
1	PPG1_T_Skew	Wilcoxon	0,5896	Ascendente	0,0062
2	PPG1_T_Kurtosis	Wilcoxon	4,8041	Ascendente	0,0070
3	SKT_T_Median	Wilcoxon	0,0060	Ascendente	0,0149
4	HR_T_Median	Wilcoxon	-2,2582	Descendente	0,0152
5	EDA_T_Kurtosis	Wilcoxon	-0,9158	Descendente	0,0159
6	HR_T_Min	Wilcoxon	-0,9555	Descendente	0,0162
7	SKT_T_Mean	Wilcoxon	0,0065	Ascendente	0,0173
8	SCR_T_Kurtosis	Wilcoxon	-1,1675	Descendente	0,0200
9	PPG1_T_Range	Wilcoxon	133,32	Ascendente	0,0240
10	PPG1_T_Max	Wilcoxon	133,32	Ascendente	0,0240
11	SCR_T_Std	Wilcoxon	0,0054	Ascendente	0,0276
12	SCR_T_Min	Wilcoxon	-0,0100	Descendente	0,0317
13	SKT_T_Max	Wilcoxon	0,0085	Ascendente	0,0336
14	SCR_SumPeakAmp	Wilcoxon	0,0373	Ascendente	0,0406
15	SCR_T_Range	Wilcoxon	0,0146	Ascendente	0,0406
16	HR_T_Skew	Wilcoxon	0,0115	Ascendente	0,0453
17	HR_T_Range	Wilcoxon	3,9771	Ascendente	0,0470
18	EDA_T_Min	Wilcoxon	-0,0075	Descendente	0,0479

#### 6.6.4. Análisis de efecto de intervención auditiva sobre estrés

Siguiendo los mismos pasos, se aplican los test estadísticos a las características psicofisiológicas para analizar la intervención auditiva comparando la ventana previa y posterior de 10 segundos en búsqueda de biomarcadores de estrés.

Los resultados obtenidos de los test estadísticos para la intervención auditiva se presentan en la tabla 6.11. De éstos se observa que para ventanas de 10 segundos no existe evidencia de que la intervención auditiva tenga efectos en contrarrestar los factores que están aumentando el estrés o arousal como eventos de la ruta, entre otros. Esto se concluye porque los biomarcadores relacionados al HR, EDA, SCR y SCL no disminuyen significativamente.

Tabla 6.11: Características psicofisiológicas con significancia menor a 0.05 para intervención auditiva

<b>N</b>	<b>Característica</b>	<b>Test</b>	<b>Dif.Media</b>	<b>Tendencia</b>	<b>p-valor</b>
1	HR_T_Mean	Wilcoxon	4,1905	Ascendente	0,0001
2	HR_T_Skew	Wilcoxon	-0,1762	Descendente	0,0002
3	HR_T_Kurtosis	Wilcoxon	-0,2685	Descendente	0,0003
4	HR_T_Pendiente	Wilcoxon	-12,98	Descendente	0,0004
5	HR_T_Median	Wilcoxon	4,1084	Ascendente	0,0005
6	HR_T_Max	Wilcoxon	5,1859	Ascendente	0,0023
7	SCR_T_Range	Wilcoxon	0,0990	Ascendente	0,0029
8	HR_T_Min	Wilcoxon	2,2994	Ascendente	0,0049
9	HR_T_Std	Wilcoxon	0,6899	Ascendente	0,0055
10	HR_T_Range	Wilcoxon	2,8864	Ascendente	0,0078
11	EDA_T_Range	Wilcoxon	0,0987	Ascendente	0,0248
12	SCR_T_Max	Wilcoxon	0,0459	Ascendente	0,0297
13	SCR_T_Min	Wilcoxon	-0,0531	Descendente	0,0340
14	SCR_SumPeakAmp	Wilcoxon	0,1702	Ascendente	0,0414

Conclusión: Tanto para la intervención háptica como auditiva no se ha encontrado una disminución significativa de los biomarcadores para estrés por lo que no se puede asegurar que estas intervenciones atenúen este estado psicofisiológico. Sin embargo, esto significa que generan un aumento en la vigilia de la persona, un “efecto cafeína” que podría sacar a la persona del riesgo de la fatiga/somnolencia en el momento, dado que durante los 10 segundos posteriores aumenta el arousal. Como se vio en la sección 6.6.2 la intervención auditiva sería la más apropiada para combatir la fatiga.

Por lo tanto, podemos intervenir para liberar del estado de somnolencia y fatiga en el momento, pero no se puede asegurar que con esa intervención estemos sacando de ese estado a la persona de manera sostenida en el tiempo. Se requeriría mantener la intervención y activarla cada vez que los signos de fatiga se vean en aumento.

### 6.6.5. Análisis de efecto de contexto sobre estrés y fatiga

Como análisis complementario se estudia el efecto de las variables de contexto sobre el estrés y la fatiga. Por un lado, se analizan las medidas capturadas comparando los estados de fatiga declarados como bajos (menor a 5 en la escala KSS) versus los altos (mayor o igual a 5 en la escala KSS) mediante el test T-pareado o Wilcoxon dependiendo si cumple o no con los supuestos, cuyos resultados se presentan en la tabla 6.12.

Tabla 6.12: Características de contexto con significancia menor a 0.05 para KSS

N	Característica	Test	Dif.Media	Tendencia	p-valor
1	temperature_T_Median	Wilcoxon	9,3917	Ascendente	0,0007
2	temperature_T_Mean	Wilcoxon	9,3903	Ascendente	0,0007
3	CO2_T_Mean	Wilcoxon	1602,2	Ascendente	0,0080
4	CO2_T_Median	Wilcoxon	1602,1	Ascendente	0,0080
5	gyroX_T_Mean	Wilcoxon	0,0033	Ascendente	0,0156
6	accZ_T_Mean	Wilcoxon	0,5312	Ascendente	0,0182
7	accZ_T_Median	Wilcoxon	0,5304	Ascendente	0,0182
8	ambientNoise_T_Mean	Wilcoxon	-36,25	Descendente	0,0278
9	gyroX_T_Median	Wilcoxon	0,0036	Ascendente	0,0365
10	ambientNoise_T_Median	Wilcoxon	-33,62	Descendente	0,0423

A su vez, se compara con un test de ANOVA de medidas repetidas multivariado para las cuatro emociones declaradas. los resultados de las características que resultan significativas se presentan en la tabla 6.13.

Tabla 6.13: Características de contexto con significancia menor a 0.05 para emociones declaradas

N	Característica	Aburrido	Contento	Estresado	Relajado	p-valor
1	CO2_T_Mean	1412,39	801,26	2534,99	715,48	0,0306
2	CO2_T_Median	1412,42	801,21	2535,01	715,64	0,0306

De los resultados obtenidos se observa un aumento significativo de la concentración de CO<sub>2</sub> en la cabina del conductor al comparar los niveles bajos de fatiga versus los niveles altos.

También se observan diferencias significativas en la concentración de CO<sub>2</sub> al comparar las emociones declaradas. En particular, para las emociones de valencia negativa (aburrido y estresado) se presenta un promedio y una mediana mayor que para las emociones de valencia positiva (contento y relajado).

De esto se puede concluir que la concentración de CO<sub>2</sub> es un factor preponderante de los estados psicofisiológicos riesgosos de fatiga y estrés en la conducción. Por lo tanto, sería importante evaluar intervenciones del entorno relacionadas al control del aire en la cabina del conductor.

Además, se puede apreciar la relación existente entre el aumento de la concentración de CO<sub>2</sub> y la presencia de aburrimiento y de fatiga donde esta última también puede ser provocada por la falta de motivación o hastío en la tarea que se está realizando.

Finalmente, queda propuesto aplicar esta metodología de análisis para una intervención de tipo auditiva, que ya fue validada para la fatiga, que de la indicación de realizar algún manejo del CO<sub>2</sub> en la cabina, como por ejemplo, con la indicación de encender el aire o de bajar la ventanilla y de esta manera afrontar la fatiga considerando también las condiciones del contexto.

## 7. Conclusiones

Este informe final resulta en un compilado de los tres informes anteriores presentados como avances y de todo el trabajo realizado con sus resultados del proyecto de investigación SUSESO “Metodología de intervención del entorno de conducción en base a identificación de fatiga, estrés y carga cognitiva mediante bioseñales” patrocinado por el Instituto de Seguridad del Trabajador (IST) y realizado por el Instituto de Sistemas Complejos de Ingeniería (ISCI), centro de excelencia alojado en la Facultad de Ciencias Físicas y Matemáticas de la Universidad de Chile.

Se ha realizado una amplia y sistemática revisión donde se ha analizado la literatura científica relativa a los estados psicofisiológicos de carga cognitiva, estrés y fatiga/somnolencia del conductor, y sobre las intervenciones que se proponen para su mitigación. Se puede observar que la mayoría de los artículos consideran estos estados de manera independiente, evidenciando una carencia de trabajos que consideren conjuntamente sus efectos en el conductor. Además, se aprecia el uso de al menos tres fuentes de datos para detectar o modelar los factores que gobiernan estos estados psicofisiológicos, a saber, medidas psicofisiológicas, de rendimiento y subjetivas (autorreporte).

Los métodos actuales de detección se verifican prevalentemente en ambientes observacionales controlados con estados psicofisiológicos inducidos por métodos artificiales bien conocidos, lo que compromete la validez ecológica de los trabajos. Sin embargo, la conducción es una tarea en la cual constantemente se está expuesto a estímulos internos, externos y tareas secundarias. Esto aumenta la relevancia de investigar estos estados psicofisiológicos en ambientes reales de conducción, considerando estados inducidos naturalmente por la tarea.

Además, como se explica ampliamente en la sección 2.8, la detección de estados psicofisiológicos - carga cognitiva, estrés y fatiga - es el primer paso para el mejoramiento de la seguridad en la conducción. El siguiente paso corresponde a utilizar un sistema de intervención que reciba la información de los estados del conductor, y que, mediante actuadores o sistemas de recomendación, genere mecanismos que permitan el cambio en su comportamiento.

Es importante destacar el valor del modelo de interacción de estados psicofisiológicos propuesto en la Figura 2.2 para considerar la influencia de un estado sobre otro. En este ámbito nuevamente se utilizan mecanismos específicos para inducir estados, y en pocas ocasiones se consideran las relaciones bidireccionales que existen entre ellos. Por lo tanto, se deben considerar estas relaciones al momento de generar actuadores y también, evaluar que su uso no sea perjudicial ni para la seguridad en la conducción, ni para el rendimiento.

Para obtener una metodología de evaluación de intervenciones del entorno de conducción se plantea el primer objetivo específico de esta investigación. Este consiste en identificar marcadores psicofisiológicos con poder explicativo y alta significancia para la fatiga, la carga cognitiva y el estrés en ambientes de conducción profesional. Esto se aborda, en parte, con los datos obtenidos del proyecto SUSESO desarrollado anteriormente [78].

Respecto a la detección de fatiga, se ha obtenido un modelo de detección con una exactitud del 95 %, y un modelo de predicción con 30 segundos de anticipación con una exactitud del 97 %. Con esto en mente, la caracterización y detección de fatiga ya puede ser catalogada como posible y por tanto, pensar en mejoras en cuanto a los métodos de registro de señales que permitan un preprocesamiento más eficiente y, por tanto, un modelo que pueda ser ejecutado en tiempo real durante la conducción.

Respecto al modelo estadístico de carga cognitiva, se encuentran diferencias significativas para las medidas psicofisiológicas estudiadas entre tramos de la ruta etiquetadas como alta carga cognitiva versus baja carga cognitiva. Al igual que en el caso de la fatiga, cumplido este hito, se podría pensar en la mejora de los métodos de adquisición de señales y preprocesamiento y, posteriormente, en el estudio de la influencia de actuadores que permitan regular a niveles adecuados de carga cognitiva.

Respecto a la identificación de biomarcadores para el estrés, con los datos obtenidos del experimento en simulador se consiguen características psicofisiológicas relacionadas al ritmo cardiaco (HR) y a la señal de actividad electrodermal (EDA). El estrés se induce a través de eventos en la ruta y circunstancias preocupantes del vehículo desplegados en un simulador

profesional, como un pinchazo o corte de frenos. Estos biomarcadores se observan en detalle en el análisis de la sección 5.6 y en el Anexo de la sección 8.

Dado lo anterior, se concluye que se cumple el primer objetivo específico de esta investigación, pues se ha identificado mediante análisis estadístico una amplia batería de marcadores psicofisiológicos con poder explicativo y alta significancia para la fatiga, la carga cognitiva y el estrés en ambientes de conducción profesional.

Respecto a las intervenciones del entorno, se ha propuesto un amplio conjunto de alternativas tras analizar lo propuesto en la literatura. Sin embargo, no es posible la validación de todas ellas a la vez porque se requeriría una gran cantidad de mediciones para obtener la significancia estadística necesaria. Además, se ha estudiado en profundidad la literatura científica más reciente (estado del arte) para definir tipos de intervenciones y criterios de selección. Con esto, se ha desarrollado la metodología para estudiar las intervenciones: se han definido las fórmulas para caracterizar la información y obtener los marcadores relevantes, y también los análisis estadísticos para comparar los indicadores obtenidos desde las bioseñales para cada intervención, considerando los estados de fatiga y estrés que son riesgosos en la conducción.

Finalmente, como cumplimiento del objetivo general de esta investigación se ha probado y validado en un ambiente real de conducción la metodología para dos tipos de intervenciones: auditiva y háptica. Las principales conclusiones de estos casos de uso son:

- “La intervención auditiva al ser aplicada provoca una disminución significativa en los indicadores de fatiga calculados como promedio y máximo de la duración de los bostezos”
- “La intervención háptica no presenta evidencia de que genere una disminución significativa en los indicadores de fatiga”
- Ni la intervención auditiva ni háptica presentan evidencia de generar una disminución significativa del estrés. Sin embargo, existe evidencia anecdótica en los videos de un .efecto cafeína”, la cual genera un aumento de la vigilia medida durante los 10 segundos posteriores a la intervención”

Por lo tanto, se ha diseñado una metodología de intervención del entorno de conducción para prevenir accidentes en base a identificación de fatiga y estrés mediante bioseñales que es reproducible y replicable para otros tipos de intervenciones que se deseen validar.

## 8. Anexos

### 8.1. Tablas de análisis estadístico por eventos de características psicofisiológicas para estrés en simulador

Tabla 8.1: Características con significancia menor a 0.05 para el evento ANIMAL

N	Característica	Test	Dif.Media	Tendencia	p-valor
1	HR_T_Range	Wilcoxon	-9,3299	Descendente	0,0009
2	HR_T_Skew	Wilcoxon	-0,2707	Descendente	0,0016
3	SCL_T_Median	Wilcoxon	0,0225	Ascendente	0,0017
4	HR_T_Max	Wilcoxon	-7,8169	Descendente	0,0020
5	HR_T_Std	Wilcoxon	-1,7198	Descendente	0,0030
6	SCL_T_Mean	Wilcoxon	0,0198	Ascendente	0,0032
7	SCR_T_Skew	Wilcoxon	-0,3613	Descendente	0,0045
8	HR_T_Min	Wilcoxon	1,5130	Ascendente	0,0052
9	SCL_T_Min	Wilcoxon	0,0127	Ascendente	0,0054
10	EDA_T_Mean	Wilcoxon	0,0227	Ascendente	0,0059
11	HR_T_Kurtosis	Wilcoxon	-1,2811	Descendente	0,0081
12	SCL_T_Max	Wilcoxon	0,0183	Ascendente	0,0081
13	HR_T_Median	Wilcoxon	0,5967	Ascendente	0,0085
14	EDA_T_Median	Wilcoxon	0,0304	Ascendente	0,0125
15	HR_T_Mean	Wilcoxon	0,4823	Ascendente	0,0136
16	HR_T_Pendiente	Wilcoxon	3,4932	Ascendente	0,0142
17	EDA_T_Skew	Wilcoxon	-0,2929	Descendente	0,0241
18	SCL_T_Kurtosis	Wilcoxon	-0,3049	Descendente	0,0316

Tabla 8.2: Características con significancia menor a 0.05 para el evento MAYOR TRÁFICO

N	Característica	Test	Dif.Media	Tendencia	p-valor
1	SCR_T_Mean	Wilcoxon	0,0059	Ascendente	0,0277
2	SCR_PeakCount	Wilcoxon	-1,4118	Descendente	0,0316
3	SCR_T_Median	Wilcoxon	0,0058	Ascendente	0,0352
4	SCR_T_Skew	Wilcoxon	0,2485	Ascendente	0,0352

Tabla 8.3: Características con significancia menor a 0.05 para el evento MENOR TRÁFICO

N	Característica	Test	Dif.Media	Tendencia	p-valor
1	PPG1_T_Pendiente	Wilcoxon	92,54	Ascendente	0,0005
2	HR_T_Min	Wilcoxon	4,3980	Ascendente	0,0032
3	HR_T_Std	Wilcoxon	-2,4514	Descendente	0,0042
4	SKT_T_Skew	Wilcoxon	-0,4542	Descendente	0,0080
5	HR_T_Range	Wilcoxon	-7,7972	Descendente	0,0087
6	HR_T_Kurtosis	Wilcoxon	0,3117	Ascendente	0,0094
7	HR_T_Max	Wilcoxon	-3,3992	Descendente	0,0173
8	HR_T_Median	Wilcoxon	0,2327	Ascendente	0,0230
9	HR_T_Mean	Wilcoxon	0,4282	Ascendente	0,0247
10	HR_T_Skew	Wilcoxon	0,0059	Ascendente	0,0283
11	HR_T_Pendiente	Wilcoxon	-1,7444	Descendente	0,0303
12	SCR_SumRiseTime	Wilcoxon	-0,3818	Descendente	0,0397
13	SCR_T_Skew	Wilcoxon	0,2385	Ascendente	0,0480

Tabla 8.4: Características con significancia menor a 0.05 para el evento VEHÍCULO AVERIADO

N	Característica	Test	Dif.Media	Tendencia	p-valor
1	SCL_T_Mean	Wilcoxon	0,0279	Ascendente	0,0008
2	EDA_T_Mean	Wilcoxon	0,0376	Ascendente	0,0013
3	SCL_T_Skew	Wilcoxon	-0,7437	Descendente	0,0013
4	SCL_T_Median	Wilcoxon	0,0331	Ascendente	0,0013
5	EDA_T_Max	Wilcoxon	0,0572	Ascendente	0,0014
6	SCL_T_Min	Wilcoxon	0,0154	Ascendente	0,0016
7	SCL_T_Max	Wilcoxon	0,0230	Ascendente	0,0025
8	EDA_T_Median	Wilcoxon	0,0320	Ascendente	0,0053
9	EDA_PsdMin	Wilcoxon	0,0000	Ascendente	0,0125
10	SCR_T_Max	Wilcoxon	0,0277	Ascendente	0,0186
11	HR_T_Min	Wilcoxon	3,3961	Ascendente	0,0211
12	HR_T_Median	Wilcoxon	2,9530	Ascendente	0,0325
13	HR_T_Mean	Wilcoxon	3,3417	Ascendente	0,0366
14	EDA_T_Std	Wilcoxon	0,0151	Ascendente	0,0411
15	SCR_T_Mean	Wilcoxon	0,0097	Ascendente	0,0436
16	EDA_PsdMax	Wilcoxon	0,1844	Ascendente	0,0461

Tabla 8.5: Características con significancia menor a 0.05 para el evento SIN FRENOS

N	Característica	Test	Dif.Media	Tendencia	p-valor
1	SCR_MeanRiseTime	Wilcoxon	0,1433	Ascendente	0,0431

Tabla 8.6: Características con significancia menor a 0.05 para el evento PINCHAZO

N	Característica	Test	Dif.Media	Tendencia	p-valor
1	PPG1_T_Mean	Wilcoxon	8,7791	Ascendente	0,0009
2	EDA_T_Max	Wilcoxon	0,0929	Ascendente	0,0001
3	SCL_T_Max	Wilcoxon	0,0556	Ascendente	0,0003
4	SCL_T_Mean	Wilcoxon	0,0453	Ascendente	0,0003
5	SCL_T_Median	Wilcoxon	0,0488	Ascendente	0,0004
6	PPG1_T_Std	Wilcoxon	20,05	Ascendente	0,0008
7	SCR_MeanPeakAmp	Wilcoxon	0,0318	Ascendente	0,0008
8	SCR_T_Std	Wilcoxon	0,0186	Ascendente	0,0008
9	EDA_T_Median	Wilcoxon	0,0500	Ascendente	0,0009
10	SCR_T_Pendiente	Wilcoxon	0,0538	Ascendente	0,0010
11	SCL_T_Min	Wilcoxon	0,0230	Ascendente	0,0010
12	EDA_T_Mean	Wilcoxon	0,0472	Ascendente	0,0011
13	EDA_T_Pendiente	Wilcoxon	0,0871	Ascendente	0,0012
14	HR_T_Max	Wilcoxon	15,37	Ascendente	0,0015
15	SCL_T_Std	Wilcoxon	0,0112	Ascendente	0,0016
16	HRV_T_Pendiente	Wilcoxon	962,24	Ascendente	0,0018
17	SCL_T_Range	Wilcoxon	0,0326	Ascendente	0,0018
18	EDA_T_Std	Wilcoxon	0,0291	Ascendente	0,0019
19	SCR_SumPeakAmp	Wilcoxon	0,0867	Ascendente	0,0021
20	EDA_T_Range	Wilcoxon	0,0897	Ascendente	0,0024
21	SCR_PeakCount	Wilcoxon	-1,5556	Descendente	0,0026
22	SCR_T_Min	Wilcoxon	-0,0278	Descendente	0,0027
23	EDA_PsdVar	Wilcoxon	0,0057	Ascendente	0,0034
24	SCL_T_Skew	Wilcoxon	-0,63	Descendente	0,0034
25	EDA_PsdMax	Wilcoxon	0,1600	Ascendente	0,0034
26	SCR_T_Range	Wilcoxon	0,0641	Ascendente	0,0039
27	HR_T_Range	Wilcoxon	12,95	Ascendente	0,0039
28	HR_T_Min	Wilcoxon	2,4204	Ascendente	0,0049
29	PPG1_T_Range	Wilcoxon	167,60	Ascendente	0,0066
30	PPG1_T_Max	Wilcoxon	167,60	Ascendente	0,0066
31	SCL_T_Kurtosis	Wilcoxon	-0,5174	Descendente	0,0071
32	HR_T_Mean	Wilcoxon	4,8373	Ascendente	0,0109
33	SCR_T_Max	Wilcoxon	0,0363	Ascendente	0,0109
34	HR_T_Pendiente	Wilcoxon	-15,89	Descendente	0,0116
35	SCR_MeanRiseTime	Wilcoxon	0,1351	Ascendente	0,0143
36	SCL_T_Pendiente	Wilcoxon	0,0333	Ascendente	0,0143
37	HR_T_Median	Wilcoxon	4,0513	Ascendente	0,0186
38	HRV_T_Min	Wilcoxon	-124,42	Descendente	0,0255
39	HR_T_Kurtosis	Wilcoxon	0,2855	Ascendente	0,0306
40	HR_T_Skew	Wilcoxon	0,1893	Ascendente	0,0306
41	HR_T_Std	Wilcoxon	1,6987	Ascendente	0,0325
42	SCR_T_Skew	Wilcoxon	0,3477	Ascendente	0,0388

Tabla 8.7: Características con significancia menor a 0.05 para el evento BICICLETA

N	Característica	Test	Dif.Media	Tendencia	p-valor
1	EDA_T_Max	Wilcoxon	0,0680	Ascendente	0,0012
2	SCR_T_Max	Wilcoxon	0,0343	Ascendente	0,0021
3	SCL_T_Max	Wilcoxon	0,0371	Ascendente	0,0033
4	EDA_T_Mean	Wilcoxon	0,0358	Ascendente	0,0033
5	EDA_T_Median	Wilcoxon	0,0353	Ascendente	0,0033
6	SCL_T_Median	Wilcoxon	0,0331	Ascendente	0,0038
7	SCL_T_Mean	Wilcoxon	0,0303	Ascendente	0,0043
8	EDA_T_Range	Wilcoxon	0,0709	Ascendente	0,0074
9	HR_T_Pendiente	Wilcoxon	26,47	Ascendente	0,0084
10	SCR_T_Std	Wilcoxon	0,0148	Ascendente	0,0096
11	HR_T_Std	Wilcoxon	2,9327	Ascendente	0,0108
12	EDA_T_Std	Wilcoxon	0,0203	Ascendente	0,0123
13	SCL_T_Min	Wilcoxon	0,0144	Ascendente	0,0123
14	SCR_T_Range	Wilcoxon	0,0627	Ascendente	0,0139
15	SCR_T_Mean	Wilcoxon	0,0055	Ascendente	0,0139
16	SCR_MeanPeakAmp	Wilcoxon	0,0362	Ascendente	0,0139
17	HR_T_Range	Wilcoxon	12,79	Ascendente	0,0156
18	PPG1_T_Pendiente	Wilcoxon	33,56	Ascendente	0,0157
19	HR_T_Max	Wilcoxon	13,05	Ascendente	0,0176
20	SCR_SumPeakAmp	Wilcoxon	0,1033	Ascendente	0,0222
21	SCR_T_Skew	Wilcoxon	0,4178	Ascendente	0,0347
22	SCL_T_Std	Wilcoxon	0,0076	Ascendente	0,0347
23	SCL_T_Range	Wilcoxon	0,0228	Ascendente	0,0386
24	SCL_T_Skew	Wilcoxon	-0,5624	Descendente	0,0429
25	SKT_T_Max	Wilcoxon	0,0064	Ascendente	0,0429
26	HR_T_Mean	Wilcoxon	3,2184	Ascendente	0,0475
27	SCR_T_Median	Wilcoxon	0,0063	Ascendente	0,0475

Tabla 8.8: Características con significancia menor a 0.05 para el evento CAMBIO DE NIVELES

N	Característica	Test	Dif.Media	Tendencia	p-valor
1	HR_T_Kurtosis	Wilcoxon	1,1019	Ascendente	0,0148
2	HR_T_Range	Wilcoxon	9,4834	Ascendente	0,0196
3	SKT_T_Pendiente	Wilcoxon	-0,0061	Descendente	0,0215
4	HR_T_Max	Wilcoxon	7,4877	Ascendente	0,0362
5	HR_T_Std	Wilcoxon	1,7397	Ascendente	0,0410
6	PPG1_T_Pendiente	Wilcoxon	-3,1709	Descendente	0,0454

## 8.2. Tablas de análisis estadístico por eventos de métricas del vehículo para estrés en simulador

Tabla 8.9: Características con significancia menor a 0.05 para el evento ANIMAL

<b>N</b>	<b>Característica</b>	<b>Test</b>	<b>Dif.Media</b>	<b>Tendencia</b>	<b>p-valor</b>
1	Freno_T_Median	Wilcoxon	0,0690	Ascendente	0,0277
2	Freno_T_Pendiente	Wilcoxon	0,1740	Ascendente	0,0436

Tabla 8.10: Características con significancia menor a 0.05 para el evento BICICLETA

<b>N</b>	<b>Característica</b>	<b>Test</b>	<b>Dif.Media</b>	<b>Tendencia</b>	<b>p-valor</b>
1	Acelerador_T_Median	Wilcoxon	0,1117	Ascendente	0,0022

Tabla 8.11: Características con significancia menor a 0.05 para el evento VEHÍCULO AVERIADO

<b>N</b>	<b>Característica</b>	<b>Test</b>	<b>Dif.Media</b>	<b>Tendencia</b>	<b>p-valor</b>
1	Freno_T_Std	Wilcoxon	0,1500	Ascendente	0,0006
2	Freno_T_Range	Wilcoxon	0,3603	Ascendente	0,0011
3	Freno_T_Max	Wilcoxon	0,3576	Ascendente	0,0012
4	Vel_T_Min	Wilcoxon	-11,1177	Descendente	0,0055
5	Freno_T_Mean	Wilcoxon	0,1543	Ascendente	0,0078
6	Aceleracion_T_Pendiente	Wilcoxon	-217,2439	Descendente	0,0092
7	Acelerador_T_Min	Wilcoxon	-0,0217	Descendente	0,0186
8	Vel_T_Range	Wilcoxon	11,3623	Ascendente	0,0319
9	Vel_T_Std	Wilcoxon	5,1743	Ascendente	0,0339
10	Vel_T_Mean	Wilcoxon	-6,1175	Descendente	0,0361
11	Freno_T_Median	Wilcoxon	0,1421	Ascendente	0,0414
12	Acelerador_T_Median	Wilcoxon	-0,0583	Descendente	0,0424

Tabla 8.12: Características con significancia menor a 0.05 para el evento MENOR TRÁFICO

<b>N</b>	<b>Característica</b>	<b>Test</b>	<b>Dif.Media</b>	<b>Tendencia</b>	<b>p-valor</b>
1	Aceleracion_T_Min	Wilcoxon	-122,92	Descendente	0,0309

Tabla 8.13: Características con significancia menor a 0.05 para el evento MAYOR TRÁFICO

<b>N</b>	<b>Característica</b>	<b>Test</b>	<b>Dif.Media</b>	<b>Tendencia</b>	<b>p-valor</b>
1	Freno_T_Kurtosis	Wilcoxon	8,0801	Ascendente	0,0180
2	Aceleracion_T_Median	Wilcoxon	39,8128	Ascendente	0,0413
3	Freno_T_Range	Wilcoxon	0,1262	Ascendente	0,0422

Tabla 8.14: Características con significancia menor a 0.05 para el evento SIN FRENOS

<b>N</b>	<b>Característica</b>	<b>Test</b>	<b>Dif.Media</b>	<b>Tendencia</b>	<b>p-valor</b>
1	Vel_T_Max	Wilcoxon	1,9931	Ascendente	0,0431

Tabla 8.15: Características con significancia menor a 0.05 para el evento PINCHAZO

<b>N</b>	<b>Característica</b>	<b>Test</b>	<b>Dif.Media</b>	<b>Tendencia</b>	<b>p-valor</b>
1	Acelerador_T_Mean	Wilcoxon	-0,0988	Descendente	0,0033
2	Acelerador_T_Median	Wilcoxon	-0,1339	Descendente	0,0033
3	Freno_T_Std	Wilcoxon	0,0712	Ascendente	0,0047
4	Freno_T_Range	Wilcoxon	0,1593	Ascendente	0,0076
5	Freno_T_Skew	Wilcoxon	-1,5050	Descendente	0,0096
6	Freno_T_Median	Wilcoxon	0,1469	Ascendente	0,0117
7	Vel_T_Median	Wilcoxon	-6,8684	Descendente	0,0119
8	Freno_T_Mean	Wilcoxon	0,1309	Ascendente	0,0121
9	Freno_T_Max	Wilcoxon	0,1732	Ascendente	0,0125
10	Vel_T_Mean	Wilcoxon	-5,7569	Descendente	0,0262
11	Acelerador_T_Min	Wilcoxon	-0,0503	Descendente	0,0329
12	Vel_T_Max	Wilcoxon	-2,6646	Descendente	0,0459

## Referencias

- [1] Abayomi, Abdultaofeek y col. "Physiological Signals Based Automobile Drivers' Stress Levels Detection Using Shape and Texture Feature Descriptors: An Experimental Study". En: *First International Conference on Real Time Intelligent Systems*. Springer. 2017, págs. 436-447.
- [2] Abd Rahman, Nurul Izzah, Dawal, Siti Zawiah Md y Yusoff, Nukman. "Driving mental workload and performance of ageing drivers". En: *Transportation research part F: traffic psychology and behaviour* 69 (2020), págs. 265-285.
- [3] Acerra, Ennia y col. "EEG-Based Mental Workload and Perception-Reaction Time of the Drivers While Using Adaptive Cruise Control". En: *International Symposium on Human Mental Workload: Models and Applications*. Springer. 2019, págs. 226-239.
- [4] Affanni, Antonio y col. "Driver's stress detection using skin potential response signals". En: *Measurement* 122 (2018), págs. 264-274.
- [5] Åkerstedt, Torbjörn y col. "Impaired alertness and performance driving home from the night shift: a driving simulator study". En: *Journal of sleep research* 14.1 (2005), págs. 17-20.
- [6] Alvarsson, Jesper J, Wiens, Stefan y Nilsson, Mats E. "Stress recovery during exposure to nature sound and environmental noise". En: *International journal of environmental research and public health* 7.3 (2010), págs. 1036-1046.
- [7] Amirah, Andi Yulita y Puspasari, Maya Arlini. "Music as Countermeasure for Driving Fatigue Using Brain Signal Indicator". En: *Proceedings of the 2019 5th International Conference on Industrial and Business Engineering*. 2019, págs. 169-172.
- [8] Antoun, Michael y col. "Driving in an urban environment, the stress response and effects of exercise". En: *Ergonomics* 61.9 (2018), págs. 1273-1281.
- [9] Antoun, Michael y col. "The acute physiological stress response to driving: A systematic review". En: *PLoS one* 12.10 (2017), e0185517.

- [10] Arun, S, Murugappan, M y Sundaraj, Kenneth. “Hypovigilance warning system: A review on driver alerting techniques”. En: *2011 IEEE Control and System Graduate Research Colloquium*. IEEE. 2011, págs. 65-69.
- [11] Auflick, Jack L. “Multivariate differences in driver workload: Test track versus on-road driving”. En: *International Conference on Applied Human Factors and Ergonomics*. Springer. 2017, págs. 927-936.
- [12] Ba, Yutao y Zhang, Wei. “A review of driver mental workload in driver-vehicle-environment system”. En: *International Conference on Internationalization, Design and Global Development*. Springer. 2011, págs. 125-134.
- [13] Backman, Ann-Lis. “Health survey of professional drivers”. En: *Scandinavian journal of work, environment & health* (1983), págs. 30-35.
- [14] Baharav, Anda y col. “Fluctuations in autonomic nervous activity during sleep displayed by power spectrum analysis of heart rate variability”. En: *Neurology* 45.6 (1995), págs. 1183-1187.
- [15] Balters, Stephanie y col. “Calm Commute: Guided Slow Breathing for Daily Stress Management in Drivers”. En: *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies* 4.1 (2020), págs. 1-19.
- [16] Berraho, M y col. “Measuring Professional Stress in Taxi Drivers in Féz, Morocco”. En: *Sante Publique* 18.3 (2006), págs. 375-387.
- [17] Bianco, Simone, Napoletano, Paolo y Schettini, Raimondo. “Multimodal car driver stress recognition”. En: *Proceedings of the 13th EAI International Conference on Pervasive Computing Technologies for Healthcare*. 2019, págs. 302-307.
- [18] Bichindaritz, Isabelle y col. “Feature selection and machine learning based multilevel stress detection from ECG Signals”. En: *International Conference on Innovation in Medicine and Healthcare*. Springer. 2017, págs. 202-213.

- [19] Boksem, Maarten AS, Meijman, Theo F y Lorist, Monicque M. “Mental fatigue, motivation and action monitoring”. En: *Biological psychology* 72.2 (2006), págs. 123-132.
- [20] Boksem, Maarten AS y Tops, Mattie. “Mental fatigue: costs and benefits”. En: *Brain research reviews* 59.1 (2008), págs. 125-139.
- [21] Bořil, Hynek, Boyraz, Pinar y Hansen, John HL. “Towards multimodal driver’s stress detection”. En: *Digital signal processing for in-vehicle systems and safety*. Springer, 2012, págs. 3-19.
- [22] Bowden, Vanessa K y col. “Lowering thresholds for speed limit enforcement impairs peripheral object detection and increases driver subjective workload”. En: *Accident Analysis & Prevention* 98 (2017), págs. 118-122.
- [23] Brown, Ivan D. “Driver fatigue”. En: *Human factors* 36.2 (1994), págs. 298-314.
- [24] Campaña “La Fatiga Mata” busca reducir accidentes y muertes de choferes de camiones en las carreteras del país. <https://www.conaset.cl/campana-la-fatiga-mata-busca-reducir-accidentes-y-muertes-de-choferes-de-camiones-en-las-carreteras-del-pais/>. Accessed: 2020-09-30.
- [25] Canada, Government of. *Road Safety in Canada*. 2010. URL: <https://tc.canada.ca/en/road-transportation/road-publications/road-safety-canada#s37> (visitado 11-09-2020).
- [26] Cech, Jan y Soukupova, Tereza. “Real-time eye blink detection using facial landmarks”. En: *Cent. Mach. Perception, Dep. Cybern. Fac. Electr. Eng. Czech Tech. Univ. Prague* (2016), págs. 1-8.
- [27] *Certificados de conductores : simulador*. <https://www.inatrans.cl/simuladores/>. Accessed: 2020-11-29.
- [28] Chai, Rifai y col. “Improving EEG-based driver fatigue classification using sparse-deep belief networks”. En: *Frontiers in neuroscience* 11 (2017), pág. 103.

- [29] Chang, Chun-Cheng, Sodnik, Jaka y Boyle, Linda Ng. “Don’t speak and drive: cognitive workload of in-vehicle speech interactions”. En: *Adjunct Proceedings of the 8th International Conference on Automotive User Interfaces and Interactive Vehicular Applications*. 2016, págs. 99-104.
- [30] Chao, Chin-Jung, Lin, Chia-Hsyang y Hsu, Shang-Hwa. “An assessment of the effects of navigation maps on drivers’ mental workloads”. En: *Perceptual and motor skills* 118.3 (2014), págs. 709-731.
- [31] Chen, Lan-lan y col. “Detecting driving stress in physiological signals based on multimodal feature analysis and kernel classifiers”. En: *Expert Systems with Applications* 85 (2017), págs. 279-291.
- [32] Choi, In-Ho y Kim, Yong-Guk. “Head pose and gaze direction tracking for detecting a drowsy driver”. En: *2014 international conference on big data and smart computing (BIGCOMP)*. IEEE. 2014, págs. 241-244.
- [33] Chowdhury, Nazi Faisal A. “Ambient temperature effects on driving”. En: *Procedia Manufacturing* 3 (2015), págs. 3123-3127.
- [34] Chui, Kwok Tai, Lytras, Miltiadis D y Liu, Ryan Wen. “A generic design of driver drowsiness and stress recognition using MOGA optimized deep MKL-SVM”. En: *Sensors* 20.5 (2020), pág. 1474.
- [35] *Comisión de Transportes aprobó proyecto que subirá las multas por conducir usando el celular: Llegarán a \$147.000*. [https://www.cnnchile.com/pais/proyecto-multas-conducir-usando-celular\\_20190822/](https://www.cnnchile.com/pais/proyecto-multas-conducir-usando-celular_20190822/). Accessed: 2020-09-30.
- [36] CONASET. *Libro del nuevo conductor automovilistas*. 2018.
- [37] Cooper, Joel M, Medeiros-Ward, Nathan y Strayer, David L. “The impact of eye movements and cognitive workload on lateral position variability in driving”. En: *Human factors* 55.5 (2013), págs. 1001-1014.
- [38] Coughlin, Joseph F, Reimer, Bryan y Mehler, Bruce. “Driver wellness, safety & the development of an awarecar”. En: *AgeLab, Mass Inst. Technol., Cambridge, MA* (2009).

- [39] Craye, Céline y Karray, Fakhri. “Driver distraction detection and recognition using RGB-D sensor”. En: *arXiv preprint arXiv:1502.00250* (2015).
- [40] Dasgupta, Anirban, Rahman, Daleef y Routray, Aurobinda. “A smartphone-based drowsiness detection and warning system for automotive drivers”. En: *IEEE transactions on intelligent transportation systems* 20.11 (2018), págs. 4045-4054.
- [41] Daviaux, Yannick y col. “Event-Related Electrodermal Response to Stress: Results From a Realistic Driving Simulator Scenario”. En: *Human Factors* 62.1 (2020), págs. 138-151.
- [42] De La Fuente, Hugo Loeches y col. “Electrophysiological and performance variations following driving events involving an increase in mental workload”. En: *European transport research review* 11.1 (2019), pág. 42.
- [43] Dinges, David F. “An overview of sleepiness and accidents”. En: *Journal of sleep research* 4 (1995), págs. 4-14.
- [44] Dogan, Daghan, Bogosyan, Seta y Acarman, Tankut. “Evaluation of driver stress level with survey, galvanic skin response sensor data, and force-sensing resistor data”. En: *Advances in Mechanical Engineering* 11.12 (2019), pág. 1687814019891555.
- [45] Doudou, M, Bouabdallah, A y Berge-Cherfaoui, V. “Driver Drowsiness Measurement Technologies: Current Research, Market Solutions, and Challenges”. En: *International Journal of Intelligent Transportation Systems Research* (2019), págs. 1-23.
- [46] Du, Yong y col. “Kernelized fuzzy rough sets based yawn detection for driver fatigue monitoring”. En: *Fundamenta Informaticae* 111.1 (2011), págs. 65-79.
- [47] Dwivedi, Kartik, Biswaranjan, Kumar y Sethi, Amit. “Drowsy driver detection using representation learning”. En: *2014 IEEE international advance computing conference (IACC)*. IEEE. 2014, págs. 995-999.

- [48] Eilebrecht, Benjamin y col. “The relevance of HRV parameters for driver workload detection in real world driving”. En: *2012 Computing in Cardiology*. IEEE. 2012, págs. 409-412.
- [49] Enokida, Susumu y col. “Assessing mental workload of in-vehicle information systems by using physiological metrics”. En: *International Conference on Human Interface and the Management of Information*. Springer. 2013, págs. 584-593.
- [50] Eskandarian, Azim y Mortazavi, Ali. “Evaluation of a smart algorithm for commercial vehicle driver drowsiness detection”. En: *2007 IEEE Intelligent Vehicles Symposium*. IEEE. 2007, págs. 553-559.
- [51] Europea, Comisión. *Road Safety*. 2020. URL: [https://ec.europa.eu/transport/road\\_safety/specialist/knowledge/fatigue\\_en](https://ec.europa.eu/transport/road_safety/specialist/knowledge/fatigue_en) (visitado 11-09-2020).
- [52] Fan, Xiao, Yin, Bao-Cai y Sun, Yan-Feng. “Yawning detection for monitoring driver fatigue”. En: *2007 International Conference on Machine Learning and Cybernetics*. Vol. 2. IEEE. 2007, págs. 664-668.
- [53] Gable, Thomas M y col. “Comparing heart rate and pupil size as objective measures of workload in the driving context: initial look”. En: *Adjunct proceedings of the 7th international conference on automotive user interfaces and interactive vehicular applications*. 2015, págs. 20-25.
- [54] Gao, Hua, Yüce, Anil y Thiran, Jean-Philippe. “Detecting emotional stress from facial expressions for driving safety”. En: *2014 IEEE International Conference on Image Processing (ICIP)*. IEEE. 2014, págs. 5961-5965.
- [55] Gaspar, John G y col. “Evaluating driver drowsiness countermeasures”. En: *Traffic injury prevention* 18.sup1 (2017), S58-S63.
- [56] Gent, Paul van y col. “Multi-level driver workload prediction using machine learning and off-the-shelf sensors”. En: *Transportation research record* 2672.37 (2018), págs. 141-152.

- [57] Goldstein, Igor Fillippe y Filgueiras, Lucia Vilela Leite. “CargoAffect: usage of affective computing to assess stress from truck drivers’ verbal communication”. En: *Proceedings of the 18th Brazilian Symposium on Human Factors in Computing Systems*. 2019, págs. 1-11.
- [58] Gopher, Daniel y Braune, Rolf. “On the psychophysics of workload: Why bother with subjective measures?” En: *Human Factors* 26.5 (1984), págs. 519-532.
- [59] Grandjean, E. “Fatigue in industry.” En: *Occupational and Environmental Medicine* 36.3 (1979), págs. 175-186.
- [60] Guo, Weiwei y col. “Driver’s mental workload estimation based on empirical physiological indicators”. En: *2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)*. IEEE. 2016, págs. 344-347.
- [61] Hajek, W y col. “Workload-adaptive cruise control—A new generation of advanced driver assistance systems”. En: *Transportation research part F: traffic psychology and behaviour* 20 (2013), págs. 108-120.
- [62] Halim, Zahid y Rehan, Mahma. “On identification of driving-induced stress using electroencephalogram signals: A framework based on wearable safety-critical scheme and machine learning”. En: *Information Fusion* 53 (2020), págs. 66-79.
- [63] Hamada, Hiroto y col. “Effect of mental workload and aging on driver distraction based on the involuntary eye movement”. En: *Advances in Human Aspects of Transportation*. Springer, 2017, págs. 349-359.
- [64] Hargutt, V y col. “Compensation for drowsiness and fatigue: A driving simulation study”. En: *International conference on traffic and transport psychology-ICTTP 2000, Held 4-7 September 2000, Berne, Switzerland- Keynotes, Symposia, Thematic Sessions, Workshops, Posters, List of Participants and word viewer-CD ROM*. 2001.
- [65] Hart, Sandra G. “NASA-task load index (NASA-TLX); 20 years later”. En: *Proceedings of the human factors and ergonomics society annual meeting*. Vol. 50. 9. Sage publications Sage CA: Los Angeles, CA. 2006, págs. 904-908.

- [66] Hart, Sandra G y Staveland, Lowell E. “Development of NASA-TLX (Task Load Index): Results of empirical and theoretical research”. En: *Advances in psychology*. Vol. 52. Elsevier, 1988, págs. 139-183.
- [67] Healey, Jennifer y Picard, Rosalind. “SmartCar: detecting driver stress”. En: *Proceedings 15th International Conference on Pattern Recognition. ICPR-2000*. Vol. 4. IEEE. 2000, págs. 218-221.
- [68] Healey, Jennifer A y Picard, Rosalind W. “Detecting stress during real-world driving tasks using physiological sensors”. En: *IEEE Transactions on intelligent transportation systems* 6.2 (2005), págs. 156-166.
- [69] Heikoop, Daniël D y col. “Acclimatizing to automation: Driver workload and stress during partially automated car following in real traffic”. En: *Transportation research part F: traffic psychology and behaviour* 65 (2019), págs. 503-517.
- [70] Hennessy, DWIGHT A y Wiesenthal, DL. “The influence of music on driver stress”. En: *Journal of applied social psychology* 30.8 (2000), págs. 1709-1719.
- [71] Hernandez, Javier y col. “AutoEmotive: bringing empathy to the driving experience to manage stress”. En: *Proceedings of the 2014 companion publication on Designing interactive systems*. 2014, págs. 53-56.
- [72] Hostens, I y Ramon, Herman. “Assessment of muscle fatigue in low level monotonous task performance during car driving”. En: *Journal of electromyography and kinesiology* 15.3 (2005), págs. 266-274.
- [73] Hulst, Monique van der, Meijman, Theo y Rothengatter, Talib. “Maintaining task set under fatigue: a study of time-on-task effects in simulated driving”. En: *Transportation research part F: traffic psychology and behaviour* 4.2 (2001), págs. 103-118.
- [74] Hwang, Yoonsook y col. “A validation study on a subjective driving workload prediction tool”. En: *IEEE Transactions on Intelligent Transportation Systems* 15.4 (2014), págs. 1835-1843.

- [75] Islam, Mir Riyanul y col. “Deep Learning for Automatic EEG Feature Extraction: An Application in Drivers’ Mental Workload Classification”. En: *International Symposium on Human Mental Workload: Models and Applications*. Springer. 2019, págs. 121-135.
- [76] Janstrup, Kira Hyldekær. *Road Safety Annual Report 2017*. 2017.
- [77] Jewett, Megan E y col. “Dose-response relationship between sleep duration and human psychomotor vigilance and subjective alertness”. En: *Sleep* 22.2 (1999), págs. 171-179.
- [78] Jimenez-Molina, Angel, Gaete, Jorge y Retamal, Cristian. *Caracterización de Fatiga Laboral a Través de Señales Psicofisiológicas*. Disponible en <https://servicios.suseso.cl/investigacion/biblioteca/estudios.html?task=download.send&id=188>. SUSESO, 2019.
- [79] Jimenez-Molina, Angel y Lira, Hernán. “Towards a continuous assessment of cognitive workload for smartphone multitasking users”. En: *The first international symposium on human mental workload*. Dublin Institute of Technology. 2017.
- [80] Jimenez-Molina, Angel, Retamal, Cristian y Lira, Hernan. “Using psychophysiological sensors to assess mental workload during web browsing”. En: *Sensors* 18.2 (2018), pág. 458.
- [81] Johns, Murray. “Rethinking the assessment of sleepiness”. En: *Sleep Medicine Reviews* 2.1 (1998), págs. 3-15.
- [82] Kamieńska-Żyła, M y Prync-Skotniczny, K. “Subjective fatigue symptoms among computer systems operators in Poland”. En: *Applied Ergonomics* 27.3 (1996), págs. 217-220.
- [83] Karatas, Nihan y col. “NAMIDA: How to reduce the cognitive workload of driver”. En: *2016 11th ACM/IEEE International Conference on Human-Robot Interaction (HRI)*. IEEE. 2016, págs. 449-450.
- [84] Khastgir, Siddartha y col. “Effect of Knowledge of Automation Capability on Trust and Workload in an Automated Vehicle: A Driving Simulator Study”. En: *International Conference on Applied Human Factors and Ergonomics*. Springer. 2018, págs. 410-420.

- [85] Kim, MH y Son, J. “On-road assessment of in-vehicle driving workload for older drivers: Design guidelines for intelligent vehicles”. En: *International Journal of Automotive Technology* 12.2 (2011), págs. 265-272.
- [86] Kim, Seyun y col. “Characterizing driver stress using physiological and operational data from real-world electric vehicle driving experiment”. En: *International Journal of Automotive Technology* 19.5 (2018), págs. 895-906.
- [87] Koesdwiady, Arief y col. “End-to-end deep learning for driver distraction recognition”. En: *International Conference Image Analysis and Recognition*. Springer. 2017, págs. 11-18.
- [88] Kompier, Michiel AJ y Di Martino, Vittorio. “Review of bus drivers’ occupational stress and stress prevention”. En: *Stress medicine* 11.1 (1995), págs. 253-262.
- [89] Kosinski, Robert J. “A literature review on reaction time”. En: *Clemson University* 10.1 (2008).
- [90] Kowsalya, Ms K y Chris, Ms P Aileen. “Driver Alertness On Android With Face And Eye Ball Movements”. En: *International Journal of Research in Engineering and Science* 2 (2014), págs. 6-9.
- [91] Lal, Saroj KL y Craig, Ashley. “Driver fatigue: electroencephalography and psychological assessment”. En: *Psychophysiology* 39.3 (2002), págs. 313-321.
- [92] Lal, Saroj KL y col. “Development of an algorithm for an EEG-based driver fatigue countermeasure”. En: *Journal of safety Research* 34.3 (2003), págs. 321-328.
- [93] Lee, Boon-Giin y Chung, Wan-Young. “Wearable glove-type driver stress detection using a motion sensor”. En: *IEEE Transactions on Intelligent Transportation Systems* 18.7 (2016), págs. 1835-1844.
- [94] Lee, Dae Seok, Chong, Teak Wei y Lee, Boon Giin. “Stress events detection of driver by wearable glove system”. En: *IEEE Sensors Journal* 17.1 (2016), págs. 194-204.

- [95] Lee, John D, Young, Kristie L y Regan, Michael A. “Defining driver distraction”. En: *Driver distraction: Theory, effects, and mitigation* 13.4 (2008), págs. 31-40.
- [96] Leeuwen, Peter van y col. “Towards a real-time driver workload estimator: an on-the-road study”. En: *Advances in Human Aspects of Transportation*. Springer, 2017, págs. 1151-1164.
- [97] Lei, Shengguang y Roetting, Matthias. “Influence of task combination on EEG spectrum modulation for driver workload estimation”. En: *Human factors* 53.2 (2011), págs. 168-179.
- [98] Li, Lingling, Chen, Yangzhou y Li, Zhenlong. “Yawning detection for monitoring driver fatigue based on two cameras”. En: *2009 12th International IEEE Conference on Intelligent Transportation Systems*. IEEE. 2009, págs. 1-6.
- [99] Liang, Yulan y Lee, John D. “A hybrid Bayesian Network approach to detect driver cognitive distraction”. En: *Transportation research part C: emerging technologies* 38 (2014), págs. 146-155.
- [100] Liao, Yuan y col. “Understanding driver response patterns to mental workload increase in typical driving scenarios”. En: *IEEE Access* 6 (2018), págs. 35890-35900.
- [101] Lim, Sejoon y Yang, Ji Hyun. “Driver state estimation by convolutional neural network using multimodal sensor data”. En: *Electronics Letters* 52.17 (2016), págs. 1495-1497.
- [102] Liu, Ke, Green, Paul y Liu, Yili. “Traffic and Ratings of Driver Workload: The Effect of the Number of Vehicles and Their Distance Headways”. En: *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*. Vol. 63. 1. SAGE Publications Sage CA: Los Angeles, CA. 2019, págs. 2134-2138.
- [103] Lyznicki, James M y col. “Sleepiness, driving, and motor vehicle crashes”. En: *Jama* 279.23 (1998), págs. 1908-1913.

- [104] Ma, Yanli y col. “Distractions intervention strategies for in-vehicle secondary tasks: An on-road test assessment of driving task demand based on real-time traffic environment”. En: *Transportation Research Part D: Transport and Environment* 63 (2018), págs. 747-754.
- [105] MacDonald, Wendy. “The impact of job demands and workload on stress and fatigue”. En: *Australian Psychologist* 38.2 (2003), págs. 102-117.
- [106] Madrid, Juan Manuel, Arce-Lopera, Carlos A y Lasso, Fabian. “Biometric Interface for Driver’s Stress Detection and Awareness”. En: *Adjunct Proceedings of the 10th International Conference on Automotive User Interfaces and Interactive Vehicular Applications*. 2018, págs. 132-136.
- [107] Makhtar, Ahmad Khushairy e Itoh, Makoto. “An Analysis of Ear Plethysmogram for Evaluation of Driver’s Mental Workload Level”. En: *International Conference on Human Interface and the Management of Information*. Springer. 2015, págs. 213-224.
- [108] Makhtar, Ahmad Khushairy y col. “A study on the effects of the cognitive workload on the driver’s blood pulse wave”. En: *2011 IEEE International Conference on Computer Applications and Industrial Electronics (ICCAIE)*. IEEE. 2011, págs. 300-302.
- [109] Makowiec-Dąbrowska, Teresa y col. “Climate conditions and work-related fatigue among professional drivers”. En: *International journal of biometeorology* 63.2 (2019), págs. 121-128.
- [110] Malik, John, Lo, Yu-Lun y Wu, Hau-tieng. “Sleep-wake classification via quantifying heart rate variability by convolutional neural network”. En: *Physiological measurement* 39.8 (2018), pág. 085004.
- [111] Manawadu, Udara E y col. “Estimating driver workload with systematically varying traffic complexity using machine learning: experimental design”. En: *International Conference on Intelligent Human Systems Integration*. Springer. 2018, págs. 106-111.
- [112] Manseer, Marcel y Riener, Andreas. “Evaluation of driver stress while transiting road tunnels”. En: *Adjunct Proceedings of the 6th International Conference on Automotive User Interfaces and Interactive Vehicular Applications*. 2014, págs. 1-6.

- [113] Marcora, Samuele M, Staiano, Walter y Manning, Victoria. “Mental fatigue impairs physical performance in humans”. En: *Journal of applied physiology* 106.3 (2009), págs. 857-864.
- [114] Matthews, Gerald. “Towards a transactional ergonomics for driver stress and fatigue”. En: *Theoretical Issues in Ergonomics Science* 3.2 (2002), págs. 195-211.
- [115] Matthews, Gerald y Desmond, Paula A. “Stress and driving performance: Implications for design and training.” En: (2001).
- [116] Matthews, Gerald y Desmond, Paula A. “Stress as a factor in the design of in-car driving enhancement systems”. En: *Le Travail Humain* 58.2 (1995), págs. 109-129.
- [117] Matthews, Gerald y Desmond, Paula A. “Task-induced fatigue states and simulated driving performance”. En: *The Quarterly Journal of Experimental Psychology: Section A* 55.2 (2002), págs. 659-686.
- [118] May, Jennifer F y Baldwin, Carryl L. “Driver fatigue: The importance of identifying causal factors of fatigue when considering detection and countermeasure technologies”. En: *Transportation research part F: traffic psychology and behaviour* 12.3 (2009), págs. 218-224.
- [119] *MediaPipe in Python*. [https://google.github.io/mediapipe/getting\\_started/python.html](https://google.github.io/mediapipe/getting_started/python.html). Accessed: 2021-12-17.
- [120] Mehler, Bruce, Reimer, Bryan y Dusek, Jeffery A. “MIT AgeLab delayed digit recall task (n-back)”. En: *Cambridge, MA: Massachusetts Institute of Technology* (2011), pág. 17.
- [121] Miller, Erika E y Boyle, Linda Ng. “Driver behavior in road tunnels: association with driver stress and performance”. En: *Transportation Research Record* 2518.1 (2015), págs. 60-67.
- [122] Miller, Erika E y Boyle, Linda Ng. “Variations in Road Conditions on Driver Stress: Insights from an On-road Study”. En: *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*. Vol. 57. 1. SAGE Publications Sage CA: Los Angeles, CA. 2013, págs. 1864-1868.

- [123] Morgan, Justin F y Hancock, Peter A. “The effect of prior task loading on mental workload: An example of hysteresis in driving”. En: *Human factors* 53.1 (2011), págs. 75-86.
- [124] Mühlbacher-Karrer, Stephan y col. “A driver state detection system—Combining a capacitive hand detection sensor with physiological sensors”. En: *IEEE Transactions on Instrumentation and Measurement* 66.4 (2017), págs. 624-636.
- [125] Munla, Nermine y col. “Driver stress level detection using HRV analysis”. En: *2015 international conference on advances in biomedical engineering (ICABME)*. IEEE. 2015, págs. 61-64.
- [126] Murphy-Chutorian, Erik y Trivedi, Mohan Manubhai. “Head pose estimation and augmented reality tracking: An integrated system and evaluation for monitoring driver awareness”. En: *IEEE Transactions on intelligent transportation systems* 11.2 (2010), págs. 300-311.
- [127] Němcová, Andrea y col. “Multimodal Features for Detection of Driver Stress and Fatigue”. En: *IEEE Transactions on Intelligent Transportation Systems* (2020).
- [128] Niezgodá, Michal y col. “Towards testing auditory–vocal interfaces and detecting distraction while driving: A comparison of eye-movement measures in the assessment of cognitive workload”. En: *Transportation research part F: traffic psychology and behaviour* 32 (2015), págs. 23-34.
- [129] *Observatorio de Seguridad Vial*. <https://www.conaset.cl/programa/observatorio-datos-estadistica/>. Accessed: 2020-09-30.
- [130] OECD. *Road Safety Annual Report 2019 Chile*. 2019.
- [131] Ohm, Christina y Ludwig, Bernd. “Estimating the Driver’s Workload”. En: *Annual Conference on Artificial Intelligence*. Springer. 2013, págs. 130-139.
- [132] Ohsuga, Mieko y col. “Classification of blink waveforms toward the assessment of driver’s arousal levels—an EOG approach and the correlation with physiological measures”. En: *International Conference on Engineering Psychology and Cognitive Ergonomics*. Springer. 2007, págs. 787-795.

- [133] *OpenCV Pose Estimation*. [https://docs.opencv.org/4.x/d7/d53/tutorial\\_py\\_pose.html](https://docs.opencv.org/4.x/d7/d53/tutorial_py_pose.html). Accessed: 2021-12-17.
- [134] Parasuraman, Raja y Davies, David Roy. *Varieties of attention*. Academic Pr, 1984.
- [135] Parasuraman, Raja y Hancock, PA. “Mitigating the adverse effects of workload, stress, and fatigue with adaptive automation”. En: *Performance under stress* (2008), págs. 45-57.
- [136] Patel, Mitesh y col. “Applying neural network analysis on heart rate variability data to assess driver fatigue”. En: *Expert systems with Applications* 38.6 (2011), págs. 7235-7242.
- [137] Pavlovskaya, Margarita, Gaisin, Ruslan y Dautov, Rustem. “Finding Correlations Between Driver Stress and Traffic Accidents: An Experimental Study”. En: *KES International Symposium on Agent and Multi-Agent Systems: Technologies and Applications*. Springer. 2017, págs. 190-199.
- [138] Philip, Pierre y col. “Fatigue, sleepiness, and performance in simulated versus real driving conditions”. En: *Sleep* 28.12 (2005), págs. 1511-1516.
- [139] Pilutti, Tom y Ulsoy, A Galip. “Identification of driver state for lane-keeping tasks: experimental results”. En: *Proceedings of the 1997 American Control Conference (Cat. No. 97CH36041)*. Vol. 5. IEEE. 1997, págs. 3370-3374.
- [140] Posner, Michael I. “Orienting of attention”. En: *Quarterly journal of experimental psychology* 32.1 (1980), págs. 3-25.
- [141] Rahman, ASM Mahfujur y col. “A novel haptic jacket based alerting scheme in a driver fatigue monitoring system”. En: *2011 IEEE International Workshop on Haptic Audio Visual Environments and Games*. IEEE. 2011, págs. 112-117.
- [142] Recarte, Miguel Ángel y col. “Mental workload and visual impairment: Differences between pupil, blink, and subjective rating”. En: *The Spanish journal of psychology* 11.2 (2008), pág. 374.

- [143] Reddy, Bhargava y col. “Real-time driver drowsiness detection for embedded system using model compression of deep neural networks”. En: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*. 2017, págs. 121-128.
- [144] Reimer, Bryan, Mehler, Bruce y Coughlin, Joseph F. “An evaluation of driver reactions to new vehicle parking assist technologies developed to reduce driver stress”. En: *Cambridge: New England University Transportation Center, Massachusetts Institute of Technology* (2010).
- [145] Rigas, George, Goletsis, Yorgos y Fotiadis, Dimitrios I. “Real-time driver’s stress event detection”. En: *IEEE Transactions on intelligent transportation systems* 13.1 (2011), págs. 221-234.
- [146] Rodrigues, João GP y col. “A mobile sensing approach to stress detection and memory activation for public bus drivers”. En: *IEEE Transactions on Intelligent Transportation Systems* 16.6 (2015), págs. 3294-3303.
- [147] Rodriguez-Ibañez, Noelia y col. “Changes in heart rate variability indexes due to drowsiness in professional drivers measured in a real environment”. En: *2012 Computing in Cardiology*. IEEE. 2012, págs. 913-916.
- [148] Russell, James A. “A circumplex model of affect.” En: *Journal of personality and social psychology* 39.6 (1980), pág. 1161.
- [149] Sagberg, Fridulv. “Road accidents caused by drivers falling asleep”. En: *Accident Analysis & Prevention* 31.6 (1999), págs. 639-649.
- [150] San, Phyo Phyo y col. “EEG-based driver fatigue detection using hybrid deep generic model”. En: *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. IEEE. 2016, págs. 800-803.
- [151] Sandberg, David y Wahde, Mattias. “Particle swarm optimization of feedforward neural networks for the detection of drowsy driving”. En: *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*. IEEE. 2008, págs. 788-793.

- [152] Seitz, Maria y col. "Measurement of electrodermal activity to evaluate the impact of environmental complexity on driver workload". En: *Proceedings of the FISITA 2012 World Automotive Congress*. Springer. 2013, págs. 245-256.
- [153] Selye, H. "Stress without distress. New York: The New American Library". En: *Inc, A Signet Book* (1974), págs. 1-51.
- [154] Sengupta, Joydeep, Baviskar, Nupur y Shukla, Surbhi. "Biosignal acquisition system for stress monitoring". En: *International Conference on Advances in Information Technology and Mobile Communication*. Springer. 2012, págs. 451-458.
- [155] Shen, Kai-Quan y col. "EEG-based mental fatigue measurement using multi-class support vector machines with confidence estimate". En: *Clinical neurophysiology* 119.7 (2008), págs. 1524-1533.
- [156] Shukla, Jainendra y col. "Feature extraction and selection for emotion recognition from electrodermal activity". En: *IEEE Transactions on Affective Computing* (2019).
- [157] Singh, Rajiv Ranjan, Conjeti, Sailesh y Banerjee, Rahul. "A comparative evaluation of neural network classifiers for stress level analysis of automotive drivers using physiological signals". En: *Biomedical Signal Processing and Control* 8.6 (2013), págs. 740-754.
- [158] Solovey, Erin T y col. "Classifying driver workload using physiological and driving performance data: two field studies". En: *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*. 2014, págs. 4057-4066.
- [159] Son, Joonwoo, Lee, Yongtae y Kim, Man-Ho. "Impact of traffic environment and cognitive workload on older drivers' behavior in simulated driving". En: *International Journal of Precision Engineering and Manufacturing* 12.1 (2011), págs. 135-141.
- [160] Son, Joonwoo, Oh, Hosang y Park, Myoungouk. "Identification of driver cognitive workload using support vector machines with driving performance, physiology and eye movement in a driving simulator". En:

*International Journal of Precision Engineering and Manufacturing* 14.8 (2013), págs. 1321-1327.

- [161] Spencer, Christine y col. “Context matters: protocol ordering effects on physiological arousal and experienced stress during a simulated driving task”. En: *2019 8th International Conference on Affective Computing and Intelligent Interaction (ACII)*. IEEE. 2019, págs. 1-7.
- [162] Stern, John A, Boyer, Donna y Schroeder, David. “Blink rate: a possible measure of fatigue”. En: *Human factors* 36.2 (1994), págs. 285-297.
- [163] Strayer, David L, Watson, Jason M y Drews, Frank A. “Cognitive distraction while multitasking in the automobile”. En: *Psychology of learning and motivation*. Vol. 54. Elsevier, 2011, págs. 29-58.
- [164] Strick, Madelijn y col. “Finding comfort in a joke: Consolatory effects of humor through cognitive distraction.” En: *Emotion* 9.4 (2009), pág. 574.
- [165] Sugiono, Sugiono, Widhayaturiyawan, Denny y Andriyani, Debrina P. “Mental Stress Evaluation of Car Driver in Different Road Complexity Using Heart Rate Variability (HRV) Analysis”. En: *Proceedings of the 2018 5th International Conference on Bioinformatics Research and Applications*. 2018, págs. 90-94.
- [166] Takahashi, Issey y Yokoyama, Kiyoko. “Development of a feedback stimulation for drowsy driver using heartbeat rhythms”. En: *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE. 2011, págs. 4153-4158.
- [167] Takei, Yoshihiro y Furukawa, Yoshimi. “Estimate of driver’s fatigue through steering motion”. En: *2005 IEEE international conference on systems, man and cybernetics*. Vol. 2. IEEE. 2005, págs. 1765-1770.
- [168] Teetor, Paul. *R cookbook: Proven recipes for data analysis, statistics, and graphics.* ” O’Reilly Media, Inc.”, 2011.
- [169] Tefft, Brian C y col. *Prevalence of motor vehicle crashes involving drowsy drivers, United States, 2009-2013*. Citeseer, 2014.

- [170] Thiffault, Pierre y Bergeron, Jacques. “Fatigue and individual differences in monotonous simulated driving”. En: *Personality and individual differences* 34.1 (2003), págs. 159-176.
- [171] Thiffault, Pierre y Bergeron, Jacques. “Monotony of road environment and driver fatigue: a simulator study”. En: *Accident Analysis & Prevention* 35.3 (2003), págs. 381-391.
- [172] Tijerina, Louis y col. “Simulator study of effects of alternative distraction mitigation strategies in driver workload manager”. En: *Transportation research record* 2248.1 (2011), págs. 81-86.
- [173] Ting, Ping-Huang y col. “Driver fatigue and highway driving: A simulator study”. En: *Physiology & behavior* 94.3 (2008), págs. 448-453.
- [174] Trutschel, Udo y col. “Heart rate measures reflect the interaction of low mental workload and fatigue during driving simulation”. En: *Proceedings of the 4th International Conference on Automotive User Interfaces and Interactive Vehicular Applications*. 2012, págs. 261-264.
- [175] Ünal, Ayca Berfu, Steg, Linda y Epstude, Kai. “The influence of music on mental effort and driving performance”. En: *Accident Analysis & Prevention* 48 (2012), págs. 271-278.
- [176] Useche, Sergio A y col. “Work stress and health problems of professional drivers: a hazardous formula for their safety outcomes”. En: *PeerJ* 6 (2018), e6249.
- [177] Utsumi, Akira y col. “Impact of Directive Visual Information on Driver’s Emergency Behavior”. En: *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*. IEEE. 2018, págs. 1344-1349.
- [178] Van Cutsem, Jeroen y col. “The effects of mental fatigue on physical performance: a systematic review”. En: *Sports medicine* 47.8 (2017), págs. 1569-1588.
- [179] Vergara, Rodrigo C. y col. “Finger Temperature: A Psychophysiological Assessment of the Attentional Statek”. En: *Frontiers in Human Neuroscience* 13.8 (2019), pág. 66.

- [180] Verma, Rohit y col. "Mining spatio-temporal data for computing driver stress and observing its effects on driving behavior". En: *Proceedings of the 26th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*. 2018, págs. 452-455.
- [181] Vicente, José y col. "Drowsiness detection using heart rate variability". En: *Medical & biological engineering & computing* 54.6 (2016), págs. 927-937.
- [182] Wang, Jeen-Shing, Lin, Che-Wei y Yang, Ya-Ting C. "A k-nearest-neighbor classifier with heart rate variability feature-based transformation algorithm for driving stress recognition". En: *Neurocomputing* 116 (2013), págs. 136-143.
- [183] Wang, Ke y col. "Detection of driver stress in real-world driving environment using physiological signals". En: *2019 IEEE 17th International Conference on Industrial Informatics (INDIN)*. Vol. 1. IEEE. 2019, págs. 1807-1814.
- [184] Wang, Ying y col. "Color Block Task: A New Surrogate Secondary Task to Measure the Impact of Drivers' Incrementally Increased Workload". En: *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*. Vol. 60. 1. SAGE Publications Sage CA: Los Angeles, CA. 2016, págs. 1889-1893.
- [185] Wang, Zheng y col. "The effect of a haptic guidance steering system on fatigue-related driver behavior". En: *IEEE Transactions on Human-Machine Systems* 47.5 (2017), págs. 741-748.
- [186] Wen, Huiying y col. "Effect of music listening on physiological condition, mental workload, and driving performance with consideration of driver temperament". En: *International journal of environmental research and public health* 16.15 (2019), pág. 2766.
- [187] Wickens, Christopher D. "Multiple resources and performance prediction". En: *Theoretical issues in ergonomics science* 3.2 (2002), págs. 159-177.

- [188] Wongphanngam, Jiramet y Pumrin, Suree. “Fatigue warning system for driver nodding off using depth image from Kinect”. En: *2016 13th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*. IEEE. 2016, págs. 1-6.
- [189] Wortelen, Bertram y col. “Monte Carlo Methods for Real-Time Driver Workload Estimation Using a Cognitive Architecture”. En: *Cognitive Infocommunications, Theory and Applications*. Springer, 2019, págs. 25-48.
- [190] Wu, Ruei-Cheng y col. “Estimating driving performance based on EEG spectrum and fuzzy neural network”. En: *2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No. 04CH37541)*. Vol. 1. IEEE. 2004, págs. 585-590.
- [191] Xie, Lian y col. “Studying the effects of freeway alignment, traffic flow, and sign information on subjective driving workload and performance”. En: *Advances in Mechanical Engineering* 11.5 (2019), pág. 1687814019853690.
- [192] Xie, Yongquan, Murphey, Yi L y Kochhar, Dev. “Personalized Driver Workload Estimation Using Deep Neural Network Learning from Physiological and Vehicle Signals”. En: *IEEE Transactions on Intelligent Vehicles* (2019).
- [193] Xing, Yang y col. “Driver workload estimation using a novel hybrid method of error reduction ratio causality and support vector machine”. En: *Measurement* 114 (2018), págs. 390-397.
- [194] Yamakoshi, Takehiro y col. “Feasibility study on driver’s stress detection from differential skin temperature measurement”. En: *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE. 2008, págs. 1076-1079.
- [195] Yang, Guosheng, Lin, Yingzi y Bhattacharya, Prabir. “A driver fatigue recognition model based on information fusion and dynamic Bayesian network”. En: *Information Sciences* 180.10 (2010), págs. 1942-1954.

- [196] Yang, Yan y col. “Driver workload detection in on-road driving environment using machine learning”. En: *Proceedings of ELM-2014 Volume 2*. Springer, 2015, págs. 389-398.
- [197] Yehuda, Nechama. “Music and stress”. En: *Journal of Adult Development* 18.2 (2011), págs. 85-94.
- [198] Yi, Dewei y col. “New driver workload prediction using clustering-aided approaches”. En: *IEEE Transactions on Systems, Man, and Cybernetics: Systems* 49.1 (2018), págs. 64-70.
- [199] Yüce, Anıl y col. “Action units and their cross-correlations for prediction of cognitive load during driving”. En: *IEEE Transactions on Affective Computing* 8.2 (2016), págs. 161-175.
- [200] Zhang, Liyan, Liu, Fan y Tang, Jinhui. “Real-time system for driver fatigue detection by RGB-D camera”. En: *ACM Transactions on Intelligent Systems and Technology (TIST)* 6.2 (2015), págs. 1-17.
- [201] Zhu, WenBo y col. “A method for recognizing fatigue driving based on Dempster-Shafer theory and fuzzy neural network”. En: *Mathematical Problems in Engineering* 2017 (2017).
- [202] Zontone, Pamela y col. “Low-Complexity Classification Algorithm to Identify Drivers’ Stress Using Electrodermal Activity (EDA) Measurements”. En: *The World Thematic Conference-Biomedical Engineering and Computational Intelligence*. Springer. 2018, págs. 25-33.
- [203] Zontone, Pamela y col. “Stress detection through electrodermal activity (EDA) and electrocardiogram (ECG) analysis in car drivers”. En: *2019 27th European Signal Processing Conference (EUSIPCO)*. IEEE. 2019, págs. 1-5.

