

UNIVERSIDAD AUTONOMA DE BAJA CALIFORNIA

FACULTAD DE INGENIERÍA

MAESTRIA Y DOCTORADO EN CIENCIAS E INGENIERÍA



**Sistema De Sensado Multimodal Inteligente Para Estudiar Los
Comportamientos Visuales Al Conducir**

**TESIS PARA OBTENER EL GRADO DE
MAESTRO EN CIENCIAS
QUE PRESENTA**

JOSUÉ SAÚL ARMENTA ESPINOZA

**DIRECTOR DE TESIS:
DRA. MARCELA DEYANIRA RODRÍGUEZ URREA**

MEXICALI, BAJA CALIFORNIA

NOVIEMBRE DEL 2020

TESIS DEFENDIDA POR

Josué Saúl Armenta Espinoza

Y APROBADA POR EL SIGUIENTE COMITÉ

Dra. Marcela Deyanira Rodríguez Urrea
Director de Tesis

Dr. Alberto Leopoldo Morán y Solares
Miembro del Comité

Dr. Irvin Hussein López Nava
Miembro del Comité

RESUMEN de la tesis de Josué Saúl Armenta Espinoza, presentada como requisito parcial para la obtención del grado de MAESTRO EN CIENCIAS en el campo de conocimientos de COMPUTACIÓN. Mexicali, Baja California, México. Noviembre del 2020.

SISTEMA DE SENSADO MULTIMODAL INTELIGENTE PARA ESTUDIAR LOS COMPORTAMIENTOS VISUALES AL CONDUCIR.

Resumen aprobador por:

Dra. Marcela Deyanira Rodríguez Urrea
Director de Tesis

La conducción de vehículos es una tarea compleja, que requiere de un buen funcionamiento visual, motor y cognitivo. El envejecimiento, al igual que algunas enfermedades degenerativas, como el Alzheimer, traen consigo un deterioro en las habilidades funcionales del adulto mayor, por lo que estos podrían considerarse poco o no aptos para conducir. La comunidad científica ha investigado de manera extensa el impacto a los comportamientos visuales y de atención que podría causar dicho deterioro sobre la habilidad de los adultos mayores para conducir de manera segura. Derivado de esto, se han desarrollado múltiples instrumentos que cuentan con la capacidad de valorar la cognición humana en diferentes dominios, como la velocidad de procesamiento, atención dividida y función ejecutiva, todos ellos utilizados al conducir. El resultado de estos exámenes es a menudo comparado con el desempeño del conductor en estudios observacionales, los cuales son llevados a cabo mediante el uso de simuladores o vehículos equipados con cámaras de video, entre otros instrumentos, con el subsecuente uso de codificadores humanos para extraer los comportamientos a estudiar durante las sesiones de manejo. Sin embargo, poca atención se le ha dado al uso de sensores y técnicas de inteligencia artificial como medio para realizar la recolección de datos. Por lo anterior, se desarrolló un sistema de sensado multimodal inteligente, el cual emplea sensores inerciales y técnicas de visión artificial para inferir hacia que zonas dentro de la cabina del vehículo dirige su atención el conductor. Estas zonas, conocidas también como Puntos de Atención Visual (PAV), están

relacionadas a la ejecución de tareas primarias y secundarias durante la conducción. El sistema detecta el movimiento de la cabeza en sus tres ejes de libertad (alabeo, cabeceo, y guiñada), y lo utiliza para inferir con una precisión del 98% hacia cual PAV, de 6 previamente definidos, el conductor dirige su atención visual. Estas inferencias, acompañadas de una marca temporal, son posteriormente convertidas a la cantidad de veces que se observó cada PAV, así como la duración de cada incidencia. El sistema incluye el uso de una aplicación, desplegada en una tableta, que recolecta automáticamente datos relacionados al contexto de la conducción, como velocidad del vehículo y ubicación. La aplicación permite también a un observador humano, conocido también como anotador, registrar las acciones del conductor en tiempo real. Se llevó a cabo un estudio naturalista con 15 adultos jóvenes (con edades de 18 a 29 años) y 15 adultos mayores (de 65 años de edad en adelante), para demostrar que este enfoque tecnológico es útil para identificar patrones y comportamientos visuales, similares a los reportados en estudios previos, los cuales utilizaron métodos tradicionales para la recolección de datos. Adicionalmente, a ambos grupos se les aplicó la misma batería de pruebas cognitivas. Los resultados del estudio indican una diferencia significativa en la cantidad de vistazos, duración de la mirada hacia los PAV, así como estado cognitivo, entre ambos grupos. Fueron halladas correlaciones entre los comportamientos visuales y el resultado de algunas pruebas cognitivas. A su vez, se encontró que, independientemente del grupo de edad, factores como la velocidad a la que se conduce o la interacción con un pasajero tienen efecto sobre los comportamientos visuales. Los resultados de este estudio son consistentes con los reportados en investigaciones anteriores.

Palabras clave: adultos mayores, sistema de sensado, comportamientos al conducir, inteligencia artificial

ABSTRACT of the thesis, presented by Josué Saúl Armenta Espinoza, in order to obtain the MASTER OF SCIENCE degree in COMPUTER SCIENCE. Mexicali, Baja California, México. November 2020.

AN INTELLIGENT MULTIMODAL SENSING SYSTEM TO STUDY DRIVER'S VISUAL BEHAVIORS.

Abstract approved by:

PhD. Marcela Deyanira Rodríguez Urrea
Thesis Advisor

Vehicle driving is a complex task, which requires good visual, motor and cognitive functions. Aging, as well as some degenerative diseases such as Alzheimer's, comes with a deterioration in the functional abilities of the elderly, so they may be considered unfit or unsuitable for driving. The scientific community has extensively researched the impact on visual and attentional behaviors that such impairment may have on the ability of older adults to drive safely. As a result, multiple instruments have been developed, that have the ability to assess human cognition in different domains, such as processing speed, divided attention, and executive function, all of which are required when driving. The results of these tests are often compared with the driver's performance in observational studies, which are conducted through the use of simulators or vehicles equipped with video cameras, among other instruments, with the subsequent use of human encoders to extract the desired behaviors to be studied during the driving sessions. However, little attention has been given to the use of sensors and artificial intelligence techniques as a means of data collection. For this reason, an intelligent multimodal sensing system was developed, which uses inertial sensors and artificial vision techniques to infer which areas within the vehicle's cabin the driver directs his attention to. These areas, also known as Visual Points of Attention (VPoA), are related to the execution of primary and secondary tasks during driving. The system detects the movement of the head on its three axes of freedom (roll, pitch, and yaw), and uses it to infer with a 98% accuracy to which VPoA, out of 6

previously defined, the driver directs his visual attention. These inferences, accompanied by a timestamp, are then converted to the number of times each VPoA was observed, as well as the duration of each incidence. The system includes the use of a table-based application, which automatically collects data related to the driving context, such as vehicle speed and location. The application also allows a human observer, also known as an annotator, to log the driver's actions in real time. A naturalistic study was conducted with 15 young adults (ages 18-29) and 15 older adults (ages 65 and older) to demonstrate that this technological approach is useful for identifying visual patterns and behaviors, similar to those reported in previous studies, which used traditional data collection methods. Additionally, the same battery of cognitive tests was applied to both groups. The results of the study indicate a significant difference in the number of glances, glance duration to the VPoAs, as well as cognitive status, between both groups. Correlations were found between visual behaviors and the result of some cognitive tests. In turn, it was found that, regardless of the age group, factors such as driving speed or interaction with a passenger have an effect on visual behaviors. The results of this study are consistent with those reported in previous research.

Keywords: older adults, sensing system, driving behaviors, artificial intelligence

Agradecimientos

A mis padres, por el inmensurable cariño y esfuerzo que han dedicado a mi crecimiento personal y profesional.

A la Dra. Marcela Rodríguez, por su extraordinaria labor como asesora. Desde la licenciatura me ha motivado a ponerme metas cada vez más grandes, en las cuales ha sido partícipe de su cumplimiento. Infinitas gracias.

Al Dr. Ángel Andrade, por su constante apoyo durante la realización de este proyecto.

Al comité de mi tesis, por su disponibilidad y oportunos comentarios hacia este trabajo. Al Dr. Leopoldo Morán, por sus atenciones, y al Dr. Hussein López, por sus consejos.

A los estudiantes y adultos mayores que participaron en los estudios para la recolección de datos.

A la Universidad Autónoma de Baja California, y a todos los maestros que han formado parte de mi aprendizaje hasta este día.

Al Consejo Nacional de Ciencia y Tecnología (CONACyT), por la beca que me fue concedida para realizar mis estudios de maestría durante el periodo 2018-2020.

Tabla de contenido

Sección	Página
Resumen	III
Abstract	V
Agradecimientos	VII
Tabla de contenido	VIII
Lista de figuras	XII
Lista de tablas	XV
Capítulo I. Introducción	17
1.1 Objetivos	20
1.1.1 Objetivo general	20
1.1.2 Objetivos específicos	20
1.2 Preguntas de investigación	20
1.3 Metodología	21
1.4 Estructura de la tesis	21
Capítulo II. Trabajo relacionado	22
2.1 Tecnologías para monitorear la postura de la cabeza	23
2.2 Estudios sobre comportamientos de conducción	24
2.2.1 Protocolo de mapeo de literatura	25
2.2.1.1 Fuentes de información	25
2.2.1.2 Cadenas de búsqueda	25
2.2.1.3 Criterios de elegibilidad	26
2.2.1.4 Proceso de selección de estudios	27
2.2.2 Resultados	28
2.3 Conclusiones	32
2.3.1 Limitaciones	32
Capítulo III. Fundamentos teóricos	33
3.1 Orientación de la cabeza	33
3.2 Clasificador k-NN	35
3.3 Inferencia de los PAV	37

3.4. Sensores inerciales	40
3.5. Conclusiones	41
Capítulo IV. Estudio de factibilidad del uso de sensores inerciales	42
4.1. Orientación de la cabeza	43
4.2 Contexto de la conducción	46
4.3 Inferencia de los PAV	47
4.4 Desempeño del clasificador k-NN	47
4.5 Diseño del estudio de factibilidad	48
4.5.1 Técnicas de reclutamiento y criterios de elegibilidad	48
4.5.2 Etapas del estudio	48
4.6 Resultados	50
4.6.1 Datos de los participantes	50
4.6.2 Cantidad de vistazos y jerarquía del camino	51
4.7 Conclusiones	54
4.7.1 Limitaciones	54
Capítulo V. Diseño del sistema	56
5.1 Requerimientos	56
5.2 Diseño funcional	57
5.2.1 Arquitectura del sistema	57
5.2.2 Sistema de Referencia de Actitud y Rumbo (AHRS)	57
5.2.3 Aplicación de Reconocimiento Facial (ARF)	58
5.2.4 Dispositivo para envío de comandos	59
5.2.5 Aplicación de Recolección, Manipulación e Inferencia de Datos (ARMID)	60
5.2.5.1 Componente de Registro de Participantes	63
5.2.5.2 Componente de Entrenamiento	63
5.2.5.3 Componente de Inferencia	67
5.2.5.4 Componente de Validación	68
5.2.5.5 Componente de Recolección de Datos del Comportamiento al Conducir (RDCC)	69

5.3 Validación del sistema	71
5.3.1 Prueba	71
5.3.2 Validación	72
5.4 Interacción con el sistema para realizar el estudio	74
Capítulo VI. Diseño del estudio de comportamientos durante la conducción	78
6.1. Participantes del estudio	78
6.1.1 Criterios de elegibilidad	78
6.1.2 Técnicas de reclutamiento	79
6.2 Etapas del estudio	79
6.2.1 Aplicación de cuestionario demográfico y batería de pruebas cognitivas	80
6.2.2 Recolección de datos de entrenamiento	84
6.2.3 Recolección de datos de comportamiento	84
6.3 Características de la ruta de manejo	85
6.4 Indicaciones en la sesión de manejo	86
6.5 Preparación y procesamiento de datos recolectados	87
6.5.1 Preparación de datos	87
6.5.2 Partición de datos	89
6.6 Análisis estadístico de datos	90
Capítulo VII. Resultados	92
7.1 Características demográficas	92
7.2 Datos recolectados	93
7.3 Batería de pruebas cognitivas	97
7.4 Comportamientos visuales al conducir	99
7.4.1 Duración de la mirada	99
7.4.2 Cantidad de vistazos	100
7.4.3 Similitud de comportamientos visuales entre grupos de edad	104
7.5 Relación entre comportamientos visuales y pruebas cognitivas	106
7.5.1 Duración de la mirada	106

7.5.2 Cantidad de vistazos	107
7.6 Relación entre los comportamientos visuales y el contexto de la conducción	109
7.6.1 Comportamientos visuales y velocidad del vehículo	110
7.6.2 Comportamientos visuales y variables del contexto de la conducción	111
7.7 Conclusiones	115
Capítulo VIII. Conclusión	117
8.1 Contribuciones	118
8.2 Limitaciones	119
8.3 Trabajo Futuro	120
Referencias	121
Apéndice A. Formato de consentimiento informado	129
Apéndice B. Descarga, compilación y configuración de ARF	130
Apéndice C. Descarga, compilación y configuración de ARMID	133

Lista de figuras

Figura	Página
1. Pasos seguidos durante la revisión previa para seleccionar estudios.	28
2. Resultados del proceso de la selección de estudios.	29
3. Publicación de artículos sobre estudios de comportamientos de adultos mayores al conducir, a través de los años.	30
4. Sistemas para describir la orientación de un cuerpo: a) ejes y movimientos de rotación de un cuerpo en tres dimensiones, b) ángulos de Euler producidos por la inclinación de un cuerpo con respecto a la Tierra.	34
5. Representación gráfica del algoritmo k-NN para un problema de clasificación de dos dimensiones.	36
6. Distribución de las instancias para las clases “A” y “B” en un conjunto de datos de entrenamiento.	37
7. PAV dentro de cabina.	38
8. Inferencia de PAV utilizando k-NN, $k = 3$.	38
9. Registro cronológico de inferencias.	39
10. Arquitectura del sistema para la recolección de datos mediante el uso de sensores.	43
11. Google Glass: a) características externas, b) ejes ortogonales en el dispositivo.	44
12. Componente de Orientación de la Cabeza en modo estático: a) al ser afectada por el movimiento del vehículo, se descarta la lectura del ángulo, b) procedimiento para generar el conjunto de datos de entrenamiento mediante Google Glass.	46
13. Comparativa del promedio de cantidad de vistazos a cada PAV, por tipo de camino.	52
14. Comparativa del promedio de la duración de la mirada, en segundos, a cada PAV, por tipo de camino.	53
15. Arquitectura de la segunda versión del sistema portable para la recolección de datos.	57
16. Componentes para cuantificar la orientación de la cabeza: a) Sistema de Referencia de Actitud y Rumbo, b) Aplicación de Reconocimiento Facial.	58

17. Logitech Gamepad F310: a) Mapeo de controles para el Componente de Validación, b) Mapeo de controles para el Componente de Recolección de Datos del Comportamiento al Conducir.	60
18. Navegación en la interfaz de usuario de la aplicación (ARMID).	62
19. PAV dentro de cabina en la segunda versión del sistema.	64
20. Acciones que se pueden realizar con los elementos (1-6) de la interfaz de usuario del Componente de Entrenamiento.	64
21. Resultados de la prueba cuantitativa para establecer el número de instancias por clase en los conjuntos de datos de entrenamiento.	66
22. Diagrama de secuencia para generar el conjunto de datos de entrenamiento.	66
23. Ejemplo de instancias almacenadas en Conjunto de Datos de Entrenamiento; la columna CLASE corresponde al PAV donde el conductor orientó la cabeza.	67
24. Interfaz de usuario del Componente de Validación: a) Coincidencia entre el PAV indicado por el sujeto y el PAV inferido, b) Discrepancia entre el PAV indicado por el sujeto y el PAV inferido.	68
25. Interfaz de usuario del Componente de Recolección de Datos del Comportamiento al Conducir.	70
26. Resultados del proceso de validación de la arquitectura. Los números en cada cuadro significan cantidad de instancias recolectadas para esa clase.	74
27. Escenario de uso para llevar a cabo la recolección de datos durante el estudio.	76
28. Diagrama de secuencia para generar el conjunto de datos de estudio.	77
29. Ubicación de los dispositivos dentro de cabina.	80
30. MMSE: a) Ejemplo de ejercicio en la prueba, donde la figura debe ser replicada por el participante, b) Puntajes para evaluar el estado mental.	81
31. TMT-A: a) Ejemplo de elementos a unir, b) Puntajes para evaluar la velocidad de procesamiento.	82
32. TMT-B: a) Ejemplo de elementos a unir, b) Puntajes para evaluar la flexibilidad mental.	82
33. DSST: a) Ejemplo de símbolos a sustituir, b) Puntajes para evaluar la atención.	83
34. DS-F y DS-B: a) Ejemplo de secuencias a repetir al derecho y al revés, b) Puntajes para evaluar la memoria de trabajo.	84
35. Fragmento de la ruta de manejo. Las flechas rojas señalan el flujo del tráfico en caminos arteriales; las flechas verdes señalan el flujo del tráfico en caminos residenciales.	85

36. Procedimiento para llevar a cabo la acción de estacionarse e indicar la ausencia de pasajero en cabina.	86
37. Aplicación de preparación de datos.	87
38. Comparativa de la estructura de la tabla para un conjunto de datos antes y después de ser preparado mediante la aplicación de preparación de datos.	88
39. Aplicación de partición de datos.	89
40. Los conjuntos de datos preparados (de estudio) son reducidos a una lista de vistazos por participante, con su respectiva duración en segundos.	90
41. Instancias recolectadas para cada PAV por grupo de edad.	97
42. Comparativa para la cantidad de vistazos y duración media de la mirada por participante con respecto a: PAV del camino en a) los jóvenes y b) adultos mayores; y los PAV restantes en c) los jóvenes y b) adultos mayores.	105
43. Correlaciones entre la duración media de la mirada por PAV y el resultado de las pruebas cognitivas.	106
44. Correlaciones entre la cantidad de vistazos por PAV y el resultado de las pruebas cognitivas.	109
45. Relación entre velocidad y comportamientos visuales hacia el área del camino con respecto a: cantidad de vistazos en a) los jóvenes y b) adultos mayores; y duración de la mirada en c) los jóvenes y b) adultos mayores.	111
46. Cantidad de vistazos por participante hacia el área de las piernas al estar detenidos en semáforos en rojo.	115

Lista de tablas

Tabla	Página
1. Cadenas de búsqueda utilizadas para cada servicio de búsqueda de referencias, filtro aplicado y notas relevantes de cada búsqueda	26
2. Cantidad de artículos encontrados por servicio de búsqueda de referencias	28
3. Publicaciones resultantes del proceso de selección de estudios	31
4. Tasas de clasificación errónea para cada combinación de parámetros	48
5. Características de los participantes	51
6. Cantidad de vistazos a cada PAV	52
7. Duración de vistazos a cada PAV	53
8. Variables registradas en un Conjunto de Datos de Validación	69
9. Variables registradas en el Conjunto de Datos del Comportamiento al Conducir (DCC)	71
10. Características demográficas de los participantes	93
11. Duración y velocidad durante el recorrido de todos los participantes	94
12. Cantidad de datos recolectados por participante del grupo de adultos jóvenes, donde cada unidad es un PAV detectado por cuadro de video	95
13. Cantidad de datos recolectados por participante del grupo de adultos mayores, donde cada unidad es un PAV detectado por cuadro de video	96
14. Resultados de la aplicación de la batería de pruebas cognitivas	98
15. Comparativa de los resultados de las pruebas cognitivas entre grupos de edad	99
16. Duración promedio de la mirada, en segundos y normalizada, hacia cada PAV por participante	100
17. Comparativa de la duración media de la mirada (segundos) por PAV entre grupos de edad	101
18. Cantidad de vistazos, en magnitud y normalizada, hacia cada PAV por participante	102
19. Comparativa de la cantidad de vistazos hacia cada PAV entre grupos de edad	104
20. Resultados de la relación entre la duración media de la mirada para cada PAV y el resultado de cada prueba cognitiva	107
21. Resultados de la relación entre cantidad de vistazos para cada PAV y el resultado de pruebas cognitivas	108
22. Resultados del análisis del coeficiente de correlación de Pearson	110

23. Duración media de la mirada, en segundos, asociada a variables del contexto de la conducción	112
24. Cantidad de vistazos, asociada a variables del contexto de la conducción	113

Capítulo I

Introducción

El envejecimiento saludable, según la definición de la Organización Mundial de la Salud, es el proceso de desarrollo y mantenimiento de la capacidad funcional que permite el bienestar en la vejez (*¿Qué Es El Envejecimiento Saludable?*, n.d.). La capacidad funcional comprende de aquello que permite a una persona ser y hacer lo que es importante para ella, como lo son capacidades físicas y mentales en buen estado. Uno de los comportamientos más característicos en el fenómeno del envejecimiento humano, y que podría mermar su capacidad funcional, es la lentitud para desempeñar tareas, es decir, una reducción en la velocidad habitual que toma realizar alguna actividad (Timothy A. Salthouse, 1996). Un procesamiento lento de información está estrechamente relacionado a déficits en diversas áreas cognitivas (como la atención visual y la memoria de trabajo), aún en adultos mayores con buena salud física y mental (Salthouse, 1991)(Salthouse, 2005). Sin embargo, otras investigaciones sugieren que esta relación no es ubicua y que depende de otros factores, cómo que tan demandante es la tarea que se lleva a cabo, experiencias previas y estímulos (Anstey et al., 2003).

Una de las actividades más comunes en la vida diaria de un adulto es la conducción de vehículos, la cual se considera demandante, ya que requiere tanto de percepción visual como de habilidades físicas y cognitivas en buen estado (Anstey et al., 2005)(Mathias & Lucas, 2009). La aptitud para conducir (*fitness to drive*) es la habilidad para conducir de manera segura, aun cuando se pudiesen padecer enfermedades físicas y mentales (Asimakopulos et al., 2012). Lo anterior quiere decir que el deterioro en la capacidad funcional de un adulto mayor, el cual va de la mano con el proceso de envejecer, no define su aptitud para conducir.

Como se mencionó anteriormente, existen diferencias individuales entre la población de adultos mayores respecto a su funcionamiento cognitivo, lo que incluye la velocidad de procesamiento de la información. No todos los adultos mayores desarrollan los mismos problemas físicos y mentales al envejecer y, como resultado, la edad no puede ser usada como base para decidir si un conductor de dicha población debería o no seguir manejando (Karlene K. Ball et al., 1988). Las habilidades funcionales (p.ej., visuales, físicas y cognitivas) son un mejor indicador para medir el desempeño de un adulto mayor al volante (Urlings et al., 2017)(Lee et al., 2003).

En estudios que comparan el desempeño para conducir entre grupos de edad bajo diferentes condiciones, tal como atender a diversos estímulos o tareas al mismo tiempo, generalmente son los adultos mayores quienes tienen los resultados más pobres (Ponds et al., 1988)(Andrews & Westerman, 2012). Estos resultados se deben a la reducción de las habilidades funcionales del adulto mayor, que podrían tener efecto sobre sus habilidades para conducir y, por lo tanto, inhabilitarlos para llevar a cabo esta actividad de manera segura (Owsley, 2013). Esta discapacidad funcional es causada usualmente por enfermedades propias del envejecimiento, pero aun en individuos con Alzheimer o demencia senil es difícil saber cuándo dejan de ser aptos para manejar, ya que aun en fases tempranas de la enfermedad se ha encontrado que esta no interfiere con sus actividades diarias, incluida la conducción de vehículos (Bennett et al., 2016). Una valoración oportuna de la aptitud de manejo podría ayudar a evitar o reducir el número de accidentes vehiculares que involucran adultos mayores. Esta valoración se realiza aplicando una batería de instrumentos para medir varios de los dominios cognitivos, tal como estado mental general, atención y concentración, memoria, función ejecutiva y habilidades visual-espaciales (Carr et al., 2011)(Piersma et al., 2016)(Bennett et al., 2016).

Por otro lado, se han realizado varios estudios para conocer cómo la atención afecta los comportamientos al conducir. Por ejemplo, cómo el deterioro de la atención en los adultos mayores puede resultar en situaciones peligrosas al conducir (Choi et al., 2019), o cómo el llevar a cabo múltiples tareas afecta los vistazos de los conductores jóvenes y adultos hacia el camino (Wechsler et al., 2018). En dichos estudios se han utilizado principalmente cámaras de video y simuladores de manejo como herramientas de

recolección de datos. Estas técnicas requieren intervención humana para codificar las actividades observadas en el video y extraer los comportamientos de interés para su posterior análisis, lo cual puede ser una tarea demandante puesto que requiere la intervención de más de un observador, tanto para agilizar el procedimiento por sí mismo como para reducir errores en la interpretación.

Se ha demostrado que la postura de la cabeza puede ser utilizada para obtener una buena aproximación de hacia dónde se dirige la mirada, y, por lo tanto, la atención visual (Murphy-Chutorian & Trivedi, 2010). En el transcurso de esta disertación, se definirán como Puntos de Atención Visual (PAV) a las áreas de la cabina de un automóvil que son foco de atención visual del conductor. Para determinar los PAV a estudiar en este trabajo, se tomaron en cuenta las categorías de los tipos de inatención que se producen al conducir, que fueron planteadas por Murphy-Chutorian & Trivedi (2010). Como se explica a continuación, estas categorías de inatención se asocian a PAV específicos de la cabina:

1. Distracción por tarea secundaria, la cual se refiere a abandonar momentáneamente la atención sobre el camino cuando, por ejemplo, al ver la pantalla del teléfono celular, interactuar con la radio, o platicar con un pasajero.
2. Inatención relacionada al manejo, directamente relacionada a tareas propias de la conducción como revisar la velocidad del vehículo en el tablero de control o los espejos retrovisores.
3. Vistazos no específicos hacia fuera del camino, tal como observar a peatones u objetos externos, lo cual se asocia con ver hacia las áreas de las ventanas frontal y laterales.

En el presente trabajo se han identificado investigaciones centradas en estudiar cómo se puede determinar la aptitud para conducir, cuyos casos de estudio no involucran el uso de tecnologías de información, las cuales facilitan la recolección de datos de comportamientos al conducir. A su vez, se identificó la falta de estudios que analicen cómo la atención visual hacia puntos dentro de la cabina se asocia con la aptitud para conducir.

Entender los efectos del envejecimiento humano sobre los comportamientos visuales al conducir, así como la posible correlación de estos con la aptitud para conducir,

motivó el desarrollo de un sistema de recolección de datos, el cual sea utilizado para estudiar los patrones de atención visual dentro del vehículo. Para esta finalidad, el sistema propuesto determina la postura de la cabeza del conductor y el contexto de la conducción. Este último se refiere a aquellas variables que pueden influenciar los comportamientos visuales, tales como tipo de camino, ubicación, y velocidad a la que se conduce. En las siguientes sub-secciones se acota el alcance de esta tesis planteando los objetivos y preguntas de investigación.

1.1 Objetivos

1.1.1 Objetivo general

Desarrollar un sistema portable de sensado multimodal inteligente que facilite la recolección de datos para estudiar las diferencias en comportamientos visuales entre conductores adultos jóvenes y adultos mayores, así como la correlación de dichos comportamientos con la aptitud para conducir.

1.1.2 Objetivos específicos

- Desarrollar un sistema portable que recolecte datos relacionados a los puntos de atención visual (PAV) y al contexto de la conducción.
- Analizar las diferencias en los comportamientos visuales entre adultos jóvenes y adultos mayores al conducir.
- Estudiar la relación entre las variables asociadas a la aptitud para conducir, y las variables relacionadas a los comportamientos visuales de los conductores, así como el posible efecto o influencia de las primeras sobre las segundas.

1.2 Preguntas de investigación

P1. ¿Cómo los comportamientos visuales se relacionan a variables del contexto de la conducción?

P2. ¿Cómo difieren los comportamientos visuales entre grupos de edad?

P3. ¿Cómo se relacionan los comportamientos visuales dentro de la cabina con una o más variables asociadas a la aptitud para conducir?

1.3 Metodología

1. Revisión de literatura, en la cual se llevó a cabo un mapeo sobre el trabajo relacionado a esta tesis. Dicha revisión permitió definir el alcance del presente trabajo e identificar áreas de oportunidad para realizar un caso de estudio, así como seleccionar las variables a recolectar durante la ejecución de este último.
2. Implementación del sistema de recolección de datos portable, mediante el desarrollo e integración de varios componentes de hardware y software, con la finalidad de recabar las variables seleccionadas en el punto anterior, así como la prueba y validación del sistema antes de ser utilizado en el caso de estudio.
3. Conducción de un estudio utilizando el sistema, en el cual se definió un protocolo para establecer los grupos de edad, cantidad de sujetos por grupo y comportamientos durante la conducción a estudiar, entre otros criterios de inclusión, además de las actividades de recolección de datos. Posterior a la ejecución del estudio, se analizaron los datos recolectados con el objetivo de contestar las preguntas de investigación.

1.4 Estructura de la tesis

El presente trabajo se divide en 8 capítulos, siendo el presente el primero de ellos. En el Capítulo 2 se presenta el trabajo relacionado a esta tesis mediante un mapeo de literatura, en el cual se identifica el estado del arte, así como áreas de oportunidad derivadas del anterior. Posteriormente, el Capítulo 3 establece los fundamentos teóricos en los que se basa el funcionamiento del sistema de recolección de datos portable, y cuya factibilidad se pone a prueba mediante un estudio en el Capítulo 4, en el cual se concluye con las limitaciones que el sistema presentó durante su primera versión. El Capítulo 5 describe cómo se abordaron estas limitaciones con la segunda versión del sistema de recolección de datos portable, del cual se describe detalladamente su arquitectura y funcionalidad. La segunda iteración del sistema es aplicada en un caso de estudio, cuyo protocolo y ejecución

se plasman en el Capítulo 6. El Capítulo 7 expone un análisis y resultado de los datos obtenidos durante el caso de estudio. Finalmente, la conclusión de esta tesis, conformada por las aportaciones, limitaciones, y trabajo futuro, es exhibida en el Capítulo 8.

Capítulo II

Trabajo relacionado

Se han realizado revisiones sistemáticas para identificar y analizar cómo diversos instrumentos validados para determinar el estado cognitivo, ayudan a valorar la capacidad de adultos mayores para conducir de manera segura (Dickerson et al., 2014)(Bennett et al., 2016). Otras revisiones han analizado cómo la influencia de factores externos, como las distracciones, merman la capacidad o el desempeño para conducir (Ferdinand & Menachemi, 2014) (Oviedo-Trespalcios et al., 2016).

Los estudios analizados en el primer grupo de revisiones sistemáticas concluyeron en la validez de algunas baterías y pruebas cognitivas, como *Trail Making Test* partes A y B (TMT-A y TMT-B), para estimar el desempeño al volante de los conductores y predecir el posible riesgo en los grupos de adultos mayores y personas con demencia senil diagnosticada de verse involucrados en futuros accidentes automovilísticos, para lo cual se ha identificado que es relevante examinar diversos dominios cognitivos, tales como el estado mental, función ejecutiva, atención, concentración y habilidad visual-espacial (Dickerson et al., 2014)(Bennett et al., 2016). De dichas pruebas, sobresale el examen *Useful Field of View* (UFOV), el cual permite medir la velocidad de procesamiento visual (el tiempo que transcurre entre recibir un estímulo visual y entenderlo); se ha determinado que este examen es confiable para predecir el desempeño al conducir del adulto mayor, ya que los sujetos con un pobre resultado en la prueba tienen el doble de riesgo de verse involucrados en accidentes automovilísticos (K K Ball et al., 2005), además de que una velocidad de procesamiento lenta está altamente relacionada a una menor aptitud para conducir (Clay et al., 2005).

Sin embargo, las revisiones sistemáticas anteriores no analizan cómo las tecnologías de monitoreo ayudaron a recolectar datos asociados a la aptitud para conducir y

comprender los comportamientos de conducción del adulto mayor. Aun cuando existe literatura que reporta avances en tecnologías de monitoreo del estado de atención de los conductores (Chou et al., 2014)(Yang & Jeong, 2015)(Ramirez et al., 2019), no es claro cómo estos avances tecnológicos se han utilizado para estudiar variables asociadas a los comportamientos de los conductores, ni cuál es la relación de dichos comportamientos con variables asociadas a la aptitud para conducir (Armenta et al., 2019).

Por otro lado, el segundo grupo de revisiones sistemáticas se centran en analizar las asociaciones entre el desempeño de la conducción y la realización de diversas tareas secundarias, tal como el uso del teléfono celular (Collet et al., 2010). Dichas revisiones analizan estudios que incluyen no sólo el uso del teléfono celular, sino también otras actividades secundarias consideradas de riesgo para la conducción, tales como hablar con pasajeros, escuchar música e interactuar con el sistema de información. Una de las revisiones concluye que, independientemente de la edad del conductor, la tarea secundaria más peligrosa es la interacción con el teléfono celular (Ferdinand & Menachemi, 2014), mientras que otra revisión se enfoca en estudiar esta actividad secundaria y su impacto sobre el desempeño al conducir (Oviedo-Trespalacios et al., 2016).

Por lo anterior, y para acotar el alcance de esta tesis, en la primera parte de este capítulo se describen de manera general estudios que analizan el uso de tecnologías para monitorizar la atención visual mientras se conduce. En la segunda parte del capítulo, y de manera más específica, se presenta un mapeo de literatura, cuyo objetivo fue identificar estudios que abordan la valoración del desempeño de los adultos mayores al conducir mediante el uso de tecnologías de la información. Finalmente, se concluye presentando las oportunidades abiertas identificadas de este análisis de trabajos relacionados.

2.1 Tecnologías para monitorear la postura de la cabeza

Se han realizado diversas propuestas tecnológicas para estimar hacia donde dirigen los conductores su atención. En Ramirez et al., (2019) se encontró que la postura de la cabeza es el indicador mayormente utilizado al estudiar la inatención al conducir. Al igual que en los resultados del mapeo de literatura, el uso de cámaras tiene prevalencia para monitorear la postura de la cabeza.

Entre los trabajos más relacionados a lo propuesto en esta tesis, se encuentra el de Segawa et al. (2014), que utilizaron sensores inerciales y GPS para desarrollar un sistema que automáticamente evalúa las habilidades requeridas para conducir de manera segura durante un programa de entrenamiento aplicado en Japón. El sistema consiste en sensores inerciales que son vestidos en la cabeza del conductor mediante una gorra y en su zapato para capturar sus movimientos. Posteriormente, con un clasificador de tipo *Support Vector Machine* (SVM, Máquina de Soporte Vectorial), cuyo modelo es entrenado en base a los comentarios de un anotador que etiquetaba las acciones de los conductores como apropiadas o inapropiadas, el sistema decide si los movimientos de pies y cabeza son catalogados como buenos o malos hábitos para la conducción segura. El estudio que se apoyó con este sistema reveló que los conductores mayores tienden a no revisar los alrededores de su vehículo, lo cual se considera una práctica peligrosa (Segawa et al., 2014).

El uso de tecnologías vestibles se ha vuelto cada vez más popular en la electrónica de consumo, evidenciado por la existencia de relojes y lentes inteligentes en el mercado (Ploetz & Healey, 2018). Estos dispositivos contienen sensores embebidos, los cuales vuelven factible y asequible la recolección de datos de comportamiento en ambientes del mundo real, en contraste al uso de instrumentación especial dentro de laboratorios para el mismo propósito (Lowden et al., 2009)(Fu et al., 2013)(Friedland et al., 2017). En este aspecto se han identificado solo dos estudios que hacen uso de los sensores inerciales montados en la cabeza, ambos pertenecientes al mismo grupo de investigación (Chou et al., 2014) (Chuang et al., 2015). En Chou et al. (2014), los autores se enfocan en analizar los movimientos de cabeza del conductor mediante un sistema basado en el uso de dos magnetómetros, con la finalidad de detectar si el conductor tenía puesta su atención sobre el camino o fuera de este. En (Chuang et al., 2015), se utiliza los datos *en crudo* provenientes de los sensores acelerómetro, giroscopio y magnetómetro de lentes inteligentes (Vuzix M100) para clasificar la orientación de la cabeza en 7 posturas previamente establecidas. Sin embargo, la postura de la cabeza requiere de datos y procesamientos adicionales para inferir hacia donde está dirigiendo su atención el conductor.

2.2 Estudios sobre comportamientos de conducción

Se realizó un mapeo de estudios sobre comportamientos de conducción que utilizaron tecnologías para recolectar datos de adultos mayores, cuyo propósito fue identificar:

- Los estudios que se han realizado para comprender los comportamientos de conducción del adulto mayor,
- Las tecnologías utilizadas para la recolección de datos,
- Y las limitaciones y ventajas que tienen las tecnologías para facilitar la recolección de datos.

2.2.1 Protocolo de mapeo de literatura

El reporte de este mapeo de literatura tomo elementos de la declaración PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*), la cual consiste en llevar a cabo una lista de comprobación de 27 puntos, basada en evidencias, con el objetivo de reportar con claridad y calidad el resultado de llevar a cabo revisiones sistemáticas y meta análisis (Moher et al., 2009).

2.2.1.1 Fuentes de información

Dado que el enfoque de esta tesis es realizar una contribución computacional para estudiar aspectos en el dominio de las ciencias de la salud, en esta revisión de literatura se utilizaron servicios de búsqueda que incluyeron las siguientes fuentes de información:

- PubMed, (motor de búsqueda de artículos en ciencias de la salud)
- ACM Digital Library (recupera artículos en ciencias e ingeniería de la computación);
- Google Scholar, IEEE Xplore Digital Library, ScienceDirect, Scopus y SpringerLink que permiten recuperar publicaciones de diversas áreas.

2.2.1.2 Cadenas de búsqueda

Dado que el propósito de la revisión de literatura es conocer los *comportamientos o patrones de conducción en adultos mayores*, se utilizó como cadena de búsqueda “(older adult OR elderly) AND (drive OR driving) AND (behavior OR fitness OR pattern)”. La cadena de búsqueda fue adaptada a cada buscador de referencias, por lo que se modificó su estructura para cada servicio tal como se muestra en la Tabla 2.1.

Para acotar la cantidad de citas recuperadas, en cantidad y por relevancia, se aplicaron los criterios que se explican a continuación. Scopus y SpringerLink ofrecen un filtro para el área de los estudios, el cual se utilizó para limitar los resultados a las ciencias de la computación. Google Scholar suele ofrecer una alta cantidad de referencias (≥ 1000) que, al ser ordenadas por relevancia, alejaban sus resultados del alcance de la revisión. Por lo anterior, se estableció como criterio limitar los resultados a las primeras 25 páginas, equivalentes a aproximadamente 300 resultados, comparables a los obtenidos mediante ScienceDirect y SpringerLink. PubMed arroja también una alta cantidad de referencias, pero el filtro Best Match redujo el número, incluyendo los resultados más relevantes.

Tabla 2.1. Cadenas de búsqueda utilizadas para cada servicio de búsqueda de referencias, filtro aplicado y notas relevantes de cada búsqueda

Servicio de búsqueda	Cadena de búsqueda	Filtro aplicado	Nota
ACM Digital Library	'+("older adult" elderly) +driv* +(behavior fitness pattern)		
Google Scholar	("older adult" OR elderly) AND (drive OR driving) AND (behavior OR fitness OR pattern)		Se tomaron las primeras 25 páginas de resultados
IEEE Xplore Digital Library	("older adult" OR elderly) AND (drive OR driving) AND (behavior OR fitness OR pattern)		
PubMed	("older adult" OR elderly) AND (drive OR driving) AND (behavior OR fitness OR pattern)	Best Match	
ScienceDirect	("older adult" OR elderly) AND (drive OR driving) AND (behavior OR fitness OR pattern)		
Scopus	TITLE-ABS-KEY(("older adult" OR elderly) AND (drive OR driving) AND (behavior OR fitness OR pattern)) AND (LIMIT- TO(SUBJAREA, "COMP"))	Computer Science	
SpringerLink	"older adult" OR elderly driv* behavior OR fitness OR pattern	Computer Science	

2.2.1.3 Criterios de elegibilidad

Se establecieron los siguientes criterios de inclusión:

1. Que incluyeran como grupo de estudio a adultos mayores a partir de 60 años de edad.
2. Que estudien uno o varios comportamientos de conducción.
3. Que los comportamientos de conducción sean monitorizados mediante el uso de por lo menos una tecnología.
4. Estudios escritos en idioma inglés
5. Artículos publicados en revistas, memorias de conferencias o como capítulos de libro.
6. No se filtraron estudios por año de la publicación.

Fueron excluidos de la revisión:

1. Publicaciones que incluían adultos mayores y de poblaciones más jóvenes, pero que no analizaban resultados por grupos de edad.

2.2.1.4 Proceso de selección de estudios

Se utilizaron Mendeley Desktop (*Mendeley Desktop*, n.d.), Mendeley Web Importer (*Mendeley Web Importer*, n.d.), y Google Sheets (*Google Sheets*, n.d.) como herramientas de apoyo al proceso de selección de estudios. Mendeley se utilizó para recolectar los metadatos de referencias. Todas las referencias obtenidas fueron exportadas a Google Sheets, el cual fue utilizado para eliminar duplicados mediante la coincidencia por la columna título, y para crear formatos que facilitaran concentrar el resultado del proceso de selección de estudios y extracción de datos. La selección de artículos con base a los criterios de elegibilidad consistió de las siguientes etapas:

- *Revisión previa.* Una vez eliminados duplicados, el siguiente paso consistió en remover aquellas referencias que estuvieran fuera del alcance de la revisión. Para lo anterior, cada artículo fue valorado individualmente para identificar el cumplimiento de los criterios de inclusión 1 y 2 (Figura 2.1). Primeramente, se revisó que el título de la publicación cumpliera con estos criterios (pregunta P1). De no ser así, se revisaba el cumplimiento de los criterios leyendo el resumen (pregunta P2).
- *Revisión de texto completo.* Se leyó a texto completo cada uno de los artículos y se verificó que cumplieran los criterios de inclusión en su totalidad (1-6) y el criterio de

exclusión. Posteriormente, se procedió a extraer los siguientes datos a los artículos incluidos:

- Año de publicación.
- Tipo de publicación
- Tecnologías utilizadas para monitoreo.
- Comportamiento de conducción analizado
- Resultados principales obtenidos

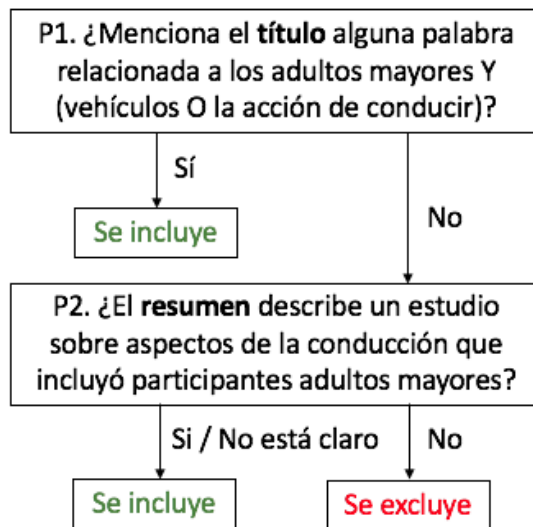


Figura 2.1. Pasos seguidos durante la revisión previa para seleccionar estudios.

2.2.2 Resultados

La búsqueda en ACM Digital Library, Google Scholar, IEEE Xplore Digital Library, PubMed, ScienceDirect, Scopus, y SpringerLink produjo un total de 1,111 referencias (Tabla 2.2).

Tabla 2.2. Cantidad de artículos encontrados por servicio de búsqueda de referencias

Servicio de búsqueda	Cantidad de artículos
ACM Digital Library	20
Google Scholar	335
IEEE Xplore Digital Library	62
PubMed	15
ScienceDirect	325
Scopus	57

SpringerLink	297
Total	1111

La identificación y eliminación de duplicados dejó 945 referencias, de las cuales 624 fueron descartados por no cumplir con los criterios establecidos al leer su título y resumen. El texto completo de los 321 artículos restantes fue examinado a detalle, donde 311 estudios no cumplieron con los criterios de inclusión (Figura 2.2).

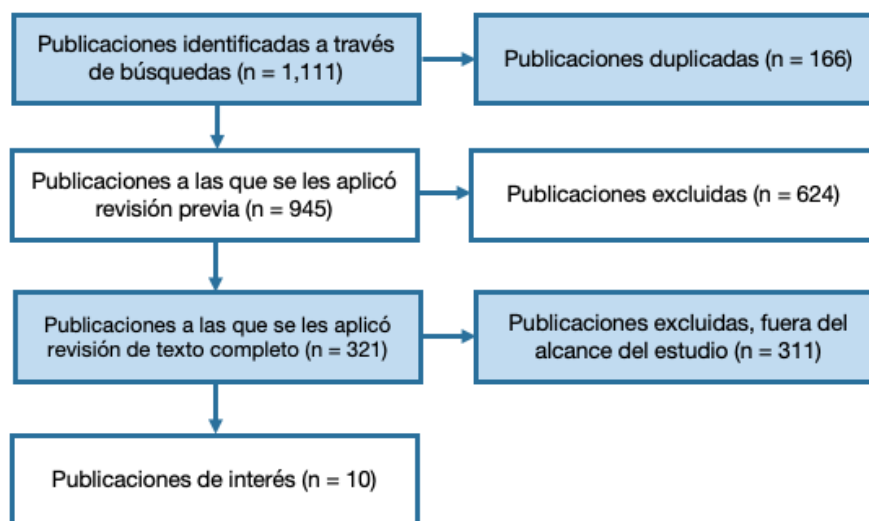


Figura 2.2. Resultados del proceso de la selección de estudios.

Durante la revisión de texto completo se identificó la cantidad y tipo de artículos que han sido publicados desde 1977 hasta 2018, año en que se llevó a cabo el mapeo de literatura. Considerando las 321 publicaciones que resultan como salida de la etapa de revisión de previa, se observa en la Figura 2.3 que existe una tendencia creciente en el estudio de comportamientos de conducción con adultos mayores, mayormente publicados en artículos de revista (273), seguido de memorias de conferencias (37) y capítulos de libro (11). Sin embargo, la mayoría de estos estudios no utilizaba algún tipo de tecnología para recolectar datos (276), o no cumplía con alguno de los otros criterios de elegibilidad establecidos. Un total de 10 publicaciones de interés fueron identificadas durante el proceso de selección de estudios (Tabla 2.3). No se incluyeron referencias provenientes de artículos relevantes no publicados.

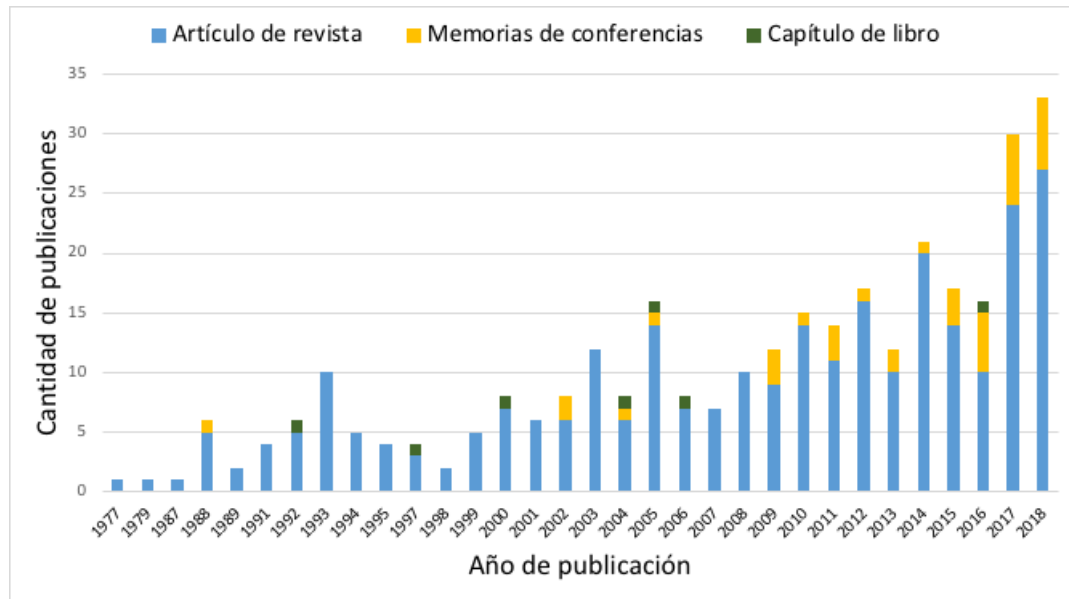


Figura 2.3. Publicación de artículos sobre estudios de comportamientos de adultos mayores al conducir, a través de los años.

En la Tabla 2.3 puede apreciarse que los estudios incluidos monitorizan la atención visual de los conductores para determinar el comportamiento del conductor. Adicionalmente, se observa la prevalencia en usar tecnologías basadas en cámaras desde hace varias décadas como herramientas de monitorización, específicamente para conocer si los conductores dirigen su atención visual al exterior de la cabina (p.ej., a señalamientos del camino) o al interior de esta (relacionada a la ejecución de tareas secundarias o distracciones). Se observa en dicha tabla que la mayoría de los estudios se enfocan en estudiar los comportamientos visuales hacia elementos del camino, y que la única instancia que estudia la atención dentro de cabina lo hace hacia un solo punto o área. En este último estudio, 30 participantes en 3 grupos de edad (adultos jóvenes, adultos de mediana edad y adultos mayores) condujeron un vehículo instrumentado a través de 350 km de carretera; durante el recorrido se les solicitaba que interactuaran con una pantalla táctil ubicada en el área de navegación del vehículo, en la cual aparecían colocados de manera aleatoria los números del 1 al 8 y debían ser presionados de manera ascendente, tarea que era repetida varias veces durante el viaje. La intención de este experimento fue comparar la cantidad de vistazos y duración de la mirada que requerían los participantes de cada grupo de edad para completar la tarea, comparando dichas variables con el resultado de pruebas cognitivas. Se

encontró que los adultos mayores separaban la mirada del camino por mas tiempo al realizar la tarea secundaria (con vistazos mayores a 2 segundos), y esto estaba relacionado a un pobre resultado en la prueba *Trail Making Test A* (Wikman & Summala, 2005).

Tabla 2.3. Publicaciones resultantes del proceso de selección de estudios

Referencia	Objetivo	Atención visual	Tecnología(s)
Ronald R. Mourant, 1979	Comparar patrones de búsqueda visual	Exterior de la cabina	Cámaras
T. Sato, et al, 2004	Comparar las estrategias visuales de dos grupos de edad.	Exterior de la cabina	Cámaras
Renge Kazumi, et al, 2004	Estudiar el desempeño de conducción mediante movimiento de cabeza	Exterior de la cabina	Cámaras
Wikman AS, et al, 2005	Analizar los cambios de atención visual carretera-objetivo	Un área al interior de la cabina	Cámaras, GPS
Kim Bo-Seong, et al, 2010	Examinar el comportamiento visual en intersecciones.	Exterior de la cabina	<i>Eye-tracker</i>
G. Fancello, et al, 2013	Analizar el comportamiento visual en rotondas.	Exterior de la cabina	<i>Eye-tracker</i> , cámara
Masahiro Tada, et al, 2014	Identificar las faltas de los adultos mayores	Exterior de la cabina	Sensores inerciales, cámaras, GPS
Mei Ying Lau, et al, 2017	Investigar el efecto de observar letreros en el camino	Exterior de la cabina	<i>Eye-tracker</i>
Ya-Lin Chen, et al, 2018	Estudiar la reacción visual ante eventos peligrosos	Exterior de la cabina	<i>Eye-tracker</i> , cámara
Sun QC, et al, 2018	Estudiar la coordinación visual-motora	Exterior de la cabina	<i>Eye-tracker</i> , cámara

Una desventaja de utilizar cámaras radica en que las grabaciones de video necesitan ser codificadas manualmente para extraer los comportamientos objetivos del estudio, descritos en la cantidad de veces que el conductor observa un elemento (al interior o exterior de la cabina) y la duración de la mirada sobre este. Para optimizar el tiempo dedicado a dicha labor, uno o varios analistas previamente entrenados deben observar secuencias cortas de video (p. ej., cada 10 segundos o menos), ya sea en muestreos aleatorios de la grabación o en periodos controlados (p. ej., cada 10 millas conducidas) para identificar posibles choques, eventos de riesgo o comportamientos específicos (Klauer et al., 2014). Sin embargo, aun cuando los eventos y comportamientos a identificar se establezcan antes de iniciar la codificación, los analistas son propensos a cometer errores. De esta manera, algunos estudios pueden requerir que los analistas estén de acuerdo en la etiqueta asignada al evento, lo cual a su vez puede significar alargar el proceso de codificación.

2.3 Conclusiones

El mapeo de literatura ayudó a obtener un panorama general del estado del arte respecto al estudio del comportamiento de los adultos mayores al conducir y de las tecnologías utilizadas para la monitorización de dichos comportamientos. Se deriva de dicha revisión de literatura que no existe ningún estudio que asocie la frecuencia y duración de la mirada hacia varios puntos de atención visual (PAV) dentro de la cabina del vehículo con el resultado de pruebas cognitivas, con la finalidad de establecer cuál o cuáles comportamientos visuales están relacionados a una pobre aptitud para conducir en los adultos mayores.

De los estudios que utilizan tecnologías para estimar la atención al conducir, se identifica que la postura de la cabeza es frecuentemente utilizada como indicador de esta, monitorizada mayormente con cámaras de video y recientemente mediante sensores inerciales. Si bien los sensores inerciales presentan la ventaja de monitorizar los comportamientos sin intervención humana, estos se ven afectados por el movimiento del automóvil. El uso de sensores inerciales, acompañado de técnicas de visión artificial, podría ser una alternativa para abordar las limitaciones de los primeros. A su vez, la fusión de los datos recolectados por ambas tecnologías estimaría con una mejor precisión la postura de la cabeza.

2.3.1 Limitaciones

La revisión previa y la revisión de texto completo no fueron realizadas por pares, por lo que existe el riesgo de que se hayan descartado o excluido publicaciones relevantes con base en la experiencia de un solo revisor. Sin embargo, la ejecución del protocolo para el mapeo de literatura y el análisis de los datos fue llevada a cabo por el autor de esta tesis y supervisada por el asesor de la misma mediante reuniones para discutir los resultados y darle validez.

Aun cuando se identificaron algunos estudios recientes posterior a la fecha de la búsqueda (semestre del periodo escolar 2018-2) mediante otras técnicas no sistemáticas, no se descarta la posibilidad de que no se hayan incluido artículos relevantes para esta tesis. Lo

anterior debido a que no se siguió un proceso de búsqueda de artículos basado en técnicas de revisión sistemática en cada semestre posterior.

Capítulo III

Fundamentos teóricos

Con motivo de estudiar los comportamientos visuales mientras se conduce, los cuales se describen mediante las variables de cantidad de vistazos y duración de la mirada hacia los Puntos de Atención Visual (PAV) dentro de la cabina del vehículo, se decidió utilizar la orientación de la cabeza para estimar hacia donde se dirige la atención. Para evitar intervención humana, los movimientos de la cabeza deben ser expresados en variables cuantificables, cuyos valores, a su vez, deben estar asociados mediante algún método a los PAV. El método utilizado en esta tesis es la técnica de aprendizaje k-NN que clasifica datos de movimientos de cabeza en los PAV. Los fundamentos teóricos de los procedimientos o métodos utilizados para identificar los comportamientos visuales serán explicados a lo largo de este capítulo.

3.1 Orientación de la cabeza

La orientación de la cabeza puede ser descrita mediante la rotación que ésta tenga en sus ejes transversal, longitudinal y vertical (Figura 3.1a), los cuales son términos usados principalmente en el contexto de la aeronáutica, y que tienen el siguiente significado:

- El eje lateral o transversal es un eje imaginario que se extiende de punta a punta de las alas del avión. El movimiento que realiza el avión alrededor de este eje se denomina *cabeceo*. En los planos del movimiento humano, corresponde al plano horizontal o axial.
- El eje longitudinal es un eje imaginario que se extiende desde la nariz a la cola del avión. El movimiento que realiza el avión alrededor de este eje se denomina *alabeo* o *balanceo*. En los planos del movimiento humano, corresponde al plano sagital.
- El eje vertical es un eje imaginario que, pasando por el centro de gravedad del avión, es perpendicular a los ejes transversal y longitudinal. Este eje está contenido en un plano

que pasa por el centro de gravedad desde arriba hacia abajo. El movimiento que realiza el avión alrededor de este eje se denomina *guiñada*. (coronal). En los planos del movimiento humano, corresponde al plano coronal o frontal.

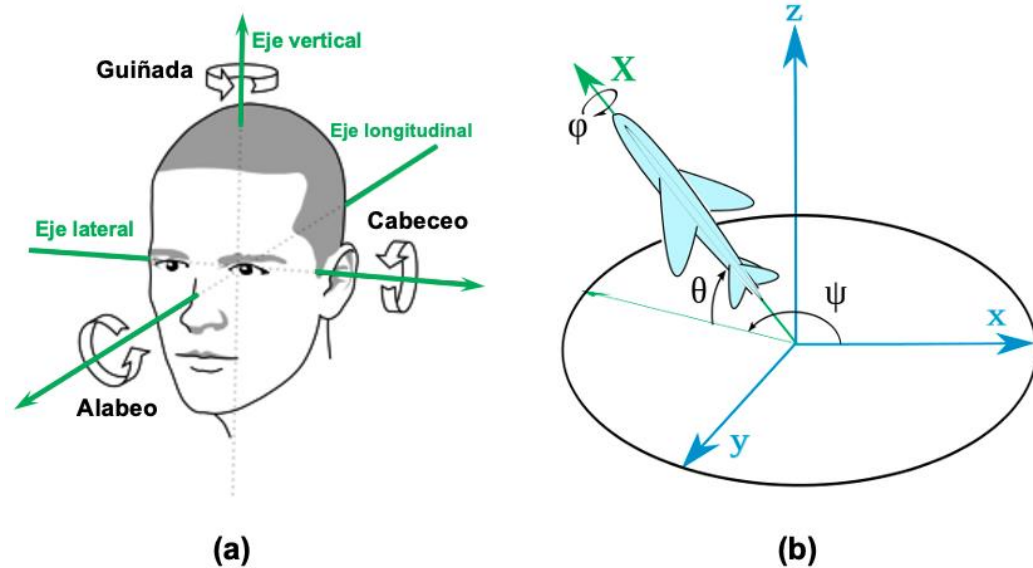


Figura 3.1. Sistemas para describir la orientación de un cuerpo: **a)** ejes y movimientos de rotación de un cuerpo en tres dimensiones, **b)** ángulos de Euler producidos por la inclinación de un cuerpo con respecto a la Tierra.

La cuantificación de los movimientos de un cuerpo a través de sus 3 ejes puede ser representadas mediante el uso de cuaterniones, ángulos de Euler, matrices de rotación, entre otros. Los ángulos de Euler constituyen un conjunto de tres coordenadas angulares que sirven para especificar la orientación de un sistema de referencia de ejes ortogonales, normalmente móvil, respecto a otro sistema de referencia de ejes ortogonales, normalmente fijos (Diebel, 2006).

La Figura 3.1b ilustra la definición de los ángulos de Euler. El sistema de referencia de ejes ortogonales fijo es representado por el plano xyz , equivalente a la Tierra, mientras que el avión representa el sistema de referencia de ejes ortogonales móvil. De este modo, los movimientos que la cabeza, en el contexto de esta tesis (Figura 3.1a) tenga en sus ejes transversal, longitudinal y vertical serán cuantificados mediante los ángulos:

- θ - ángulo de cabeceo, o Euler X
- φ - ángulo de alabeo, o Euler Y

- ψ - ángulo de guiñada, o Euler Z

Por su facilidad de interpretación y manejo dentro de sistemas computacionales, durante el desarrollo de la tesis se utilizarán los ángulos de Euler para cuantificar la orientación de la cabeza dentro de la cabina del vehículo.

3.2 Clasificador k-NN

El clasificador *k-Nearest Neighbors* (k-NN, k-vecinos más cercanos,) es un método de clasificación y regresión supervisado, no paramétrico y basado en instancias, lo cual significa que no produce una función de mapeo durante la etapa de entrenamiento; únicamente utiliza los datos de entrenamiento para hacer predicciones durante la etapa de inferencia (Altman, 1992).

Teniendo los datos de entrenamiento previamente almacenados, el algoritmo recibe una nueva observación y, utilizando el principio de similitud (usualmente la distancia euclidiana entre dos instancias cuando sus variables son de tipo numérico), calcula cuáles de las instancias registradas en el proceso de entrenamiento son *más parecidas* a la nueva observación.

La similitud entre dos instancias, utilizando distancia euclidiana, es calculada por la siguiente formula:

$$d = \sqrt{(X_1 - X_2)^2 + (Y_1 - Y_2)^2 + (Z_1 - Z_2)^2}$$

donde d es la distancia euclidiana entre dos instancias, $X_1Y_1Z_1$ son los valores de las variables de una instancia cuya clase se desconoce y $X_2Y_2Z_2$ son los valores de las variables de una instancia en el conjunto de datos de entrenamiento. Una vez calculada la distancia euclidiana entre cada una de las instancias en el conjunto de datos de entrenamiento y la instancia sin etiqueta, k-NN ordena dichas distancias de menor a mayor, toma la etiqueta o clase mas repetida entre las k instancias con distancias menores y se la asigna a la instancia cuya clase se desconoce.




Figura 3.2. Representación gráfica del algoritmo k-NN para un problema de clasificación de dos dimensiones.

Un ejemplo del funcionamiento del k-NN se explica utilizando la Figura 3.2. Como se observa, la etiqueta que el clasificador asignará a una instancia nueva (círculo verde) es diferente cuando se utiliza $k = 3$ (por moda, triángulo rojo) y $k = 5$ (por moda, cuadrado azul). Se considera una buena práctica no utilizar $k = 1$, ya que solo se estaría tomando la clase de la instancia más cercana, ignorando a los demás vecinos. A su vez, para evitar empates entre clases se sugiere utilizar valores de k impares; si se hubiera utilizado $k = 4$ para el ejemplo de la figura anterior, el clasificador no podría decidir a que clase pertenece la instancia desconocida.

Para que el clasificador k-NN tenga un buen desempeño, el conjunto de datos de entrenamiento debe cumplir con dos requisitos:

- Entre clases, las instancias de estas deben estar lo suficientemente separadas (o formar agrupamientos), de tal forma que las clases sean distinguibles las unas de las otras.
- Dentro de las clases, las instancias que le pertenecen a cada una deben tener una corta distancia entre sí, de tal manera que cualquier instancia sin clase se identifique correctamente con las instancias más *parecidas* a ésta.

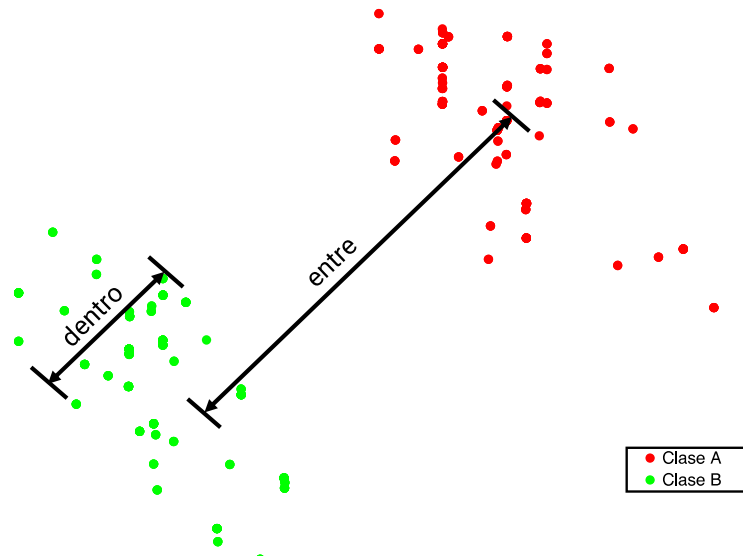


Figura 3.3. Distribución de las instancias para las clases “A” y “B” en un conjunto de datos de entrenamiento.

La representación gráfica en dos o tres dimensiones de un conjunto de datos (véase Figura 3.3) es una técnica ampliamente utilizada para verificar que éste cumpla con los requisitos anteriores. Sin embargo, y como se detallará en capítulos posteriores, técnicas de validación de modelos como *cross-validation* (validación cruzada) son utilizadas para cuantificar la calidad de los datos de entrenamiento como variables predictoras.

3.3 Inferencia de los PAV

Para el propósito de esta tesis, un PAV es una zona de la cabina del automóvil hacia el cual el conductor orienta su cabeza. De acuerdo a la figura 3.4, se definieron siete PAV, que incluyen la zona del *camino* identificada como clase 0, *espejos retrovisores central* (1), *izquierdo* (2) y *derecho* (3), *tablero de control* (4), área de control del *radio/clima* (5) y del *pasajero* (6).



Figura 3.4. PAV dentro de cabina.

Para estimar el PAV, bastaría con generar un conjunto de datos de entrenamiento donde cada instancia sea conformada por una variable controlada y tres variables predictoras:

- Como variable controlada, la clase asignada a cada PAV
- Como variables predictoras, los ángulos de Euler en X, Y, y Z que se producen cuando la cabeza se orienta hacia dicho PAV.

Posteriormente, los ángulos de Euler producidos por cada movimiento de la cabeza serán utilizados como entrada para un clasificador k-NN, el cual inferirá el PAV al cual se observa.

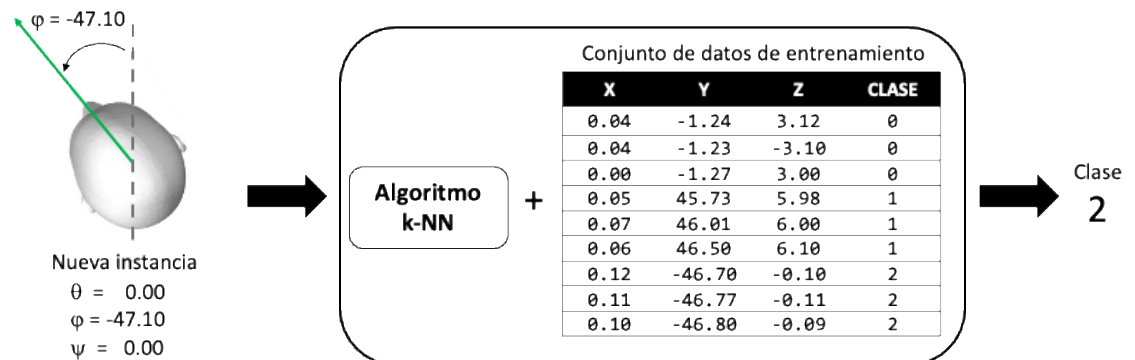



Figura 3.5. Inferencia de PAV utilizando k-NN, $k = 3$.

Este procedimiento puede observarse en la Figura 3.5, en la cuál la orientación de la cabeza hacia la izquierda es etiquetada como perteneciente a la clase “2”, o retrovisor izquierdo, ya que los valores para sus ángulos de Euler son similares a los que poseen las instancias de esta misma clase en el conjunto de datos de entrenamiento.

Debido a que algunos dispositivos de sensado pueden contar con tasas de muestro irregulares, como es el caso de teléfonos celulares, fue necesario implementar un mecanismo para determinar la duración real de cada inferencia. Por lo anterior, se llevó un registro cronológico del resultado de cada clasificación, agregando la marca temporal (*timestamp*) del momento en el que fue inferido el PAV, creando así la tupla *timestamp-clase*. De esta forma, se mantiene un registro de los datos como se muestra en la Figura 3.6, cuya estructura cumple dos propósitos:

Timestamp	Clase
28 de marzo de 2020 16:19:47	0
28 de marzo de 2020 16:19:48	0
28 de marzo de 2020 16:19:49	1
28 de marzo de 2020 16:19:50	1
28 de marzo de 2020 16:19:51	0
28 de marzo de 2020 16:19:52	0
28 de marzo de 2020 16:19:53	0



PAV	Duración
0	1 seg.
1	1 seg.
0	2 seg.

Figura 3.6. Registro cronológico de inferencias.

1. Calcular la duración de la mirada hacia cada PAV, considerando como *una mirada* el conjunto de entradas, que, de manera consecutiva e ininterrumpida, compartan un mismo PAV. La duración de la mirada es calculada mediante la diferencia del *timestamp* entre la instancia más reciente y la más antigua para cada agrupación.
2. Reducir la dimensión del registro de datos mediante el conteo de las duraciones para un mismo PAV, el cual revela cuantas veces fue observado. Es necesario contar las agrupaciones y no las instancias, ya que las primeras son producto de que se abandone la atención en otro grupo de PAV, seguido de que se observe este nuevamente, y finalmente se abandone para observar otro. Por ejemplo, en la figura 3.6, el PAV 0 fue observado dos veces, mientras que el PAV 1 solo una vez.

De esta manera, es posible saber cuántas veces fue observado cada PAV y cuál fue la duración de la mirada en cada incidencia, variables que se utilizan en esta tesis para analizar comportamientos visuales.

3.4. Sensores inerciales

Como se mencionó en el capítulo de trabajo relacionado, algunos estudios utilizaron sensores inerciales para medir la magnitud de la orientación de la cabeza en sus tres ejes mientras se conducía. Las unidades de medición inercial (IMU, *Inertial Measurement Unit*) son dispositivos portátiles, de bajo costo, y las cuales consisten en pequeñas cajas que contienen sensores, tales como acelerómetros, magnetómetros y giroscopios, así como componentes adicionales, que pueden ser baterías, módulos de comunicación y microprocesadores. Los sensores mencionados anteriormente se definen a continuación:

- Un acelerómetro es un dispositivo que mide la aceleración experimentada por un objeto, es decir, la que ocurre de manera instantánea en su marco de reposo. Son utilizados por los sistemas de navegación en aeronaves y misiles, así como teléfonos celulares, para detectar el cambio en la velocidad lineal del cuerpo o dispositivo. La unidad de medición más común para este sensor es el metro sobre segundo al cuadrado (m/s^2).
- Un magnetómetro es un dispositivo que mide magnetismo, es decir, la dirección, fuerza y cambios relativos en un campo magnético en una ubicación particular. La aplicación más conocida de este sensor es el compás, el cual se utiliza para medir la dirección del campo magnético de la Tierra. En el campo de la aeronáutica, los compases son utilizados para conocer el rumbo de las aeronaves, es decir, la dirección en la que apunta el eje longitudinal de estos cuerpos con respecto al norte geográfico o magnético. La medición del campo magnético es expresada en Gauss (G) o Microteslas (μT), donde $1G = 100\mu T$.
- Un giroscopio es un dispositivo utilizado para medir o mantener la orientación y velocidad angular de un cuerpo; se puede representar como un disco giratorio cuyo eje de rotación es libre de tomar cualquier orientación. Al rotar, la orientación del eje no es afectada por inclinar o rotar la montura sobre la cual se encuentre instalado el disco, debido a que esta conserva su momento angular. Son utilizados en sistemas de

navegación inercial, apoyo en la estabilidad de vehículos, entre otras aplicaciones. La velocidad angular de un cuerpo puede ser expresada en grados sobre segundo ($^{\circ}/s$) o radianes sobre segundo (rad/s), donde $360^{\circ} = 2\pi rad$.

Debido a sus múltiples aplicaciones, los sensores inerciales gozan de gran popularidad y se encuentran embebidos en una miríada de dispositivos, los cuales van desde sistemas de navegación militares y comerciales, hasta electrónica de consumo como teléfonos celulares y dispositivos vestibles (*wearables*), tales como relojes y lentes inteligentes (*smart watches* y *glasses*, respectivamente) (Tamura, 2014).

Una de las aplicaciones más comunes para los sensores antes mencionados son los sistemas de referencia de orientación y rumbo (conocidos como AHRS, *Attitude and Head Reference System*). En estos últimos, los datos emitidos por los sensores inerciales pueden ser combinados y procesados para estimar con una gran precisión la orientación relativa de un sistema de referencia inerte móvil sobre un sistema de referencia fijo, como lo puede ser la Tierra. Por lo tanto, mediante el uso de sensores inerciales, es posible cuantificar los movimientos de guiñada, cabeceo y alabeo del cuerpo sobre el cual se encuentran posicionados.

3.5. Conclusiones

Con base en lo explicado en las secciones anteriores, se propuso al iniciar el proyecto, que los requisitos funcionales que debe cumplir el sistema desarrollado en este trabajo son los siguientes:

1. Seleccionar un dispositivo que cuantifique la orientación de la cabeza mediante ángulos de Euler.
2. Asociar los valores de los ángulos Euler X, Y, y Z a un PAV, mediante un clasificador k-NN, y registrar cada inferencia junto a una marca temporal (*timestamp*).
3. Convertir el registro cronológico de inferencias en cantidad de veces que se observó cada PAV y la duración de la mirada en cada incidencia.

Capítulo IV

Estudio de factibilidad del uso de sensores inerciales

Este estudio tiene como propósito lo siguiente:

1. Comprobar si los datos recolectados únicamente mediante el uso de sensores inerciales son suficientes para estimar la postura de la cabeza hacia los PAV dentro de la cabina de un vehículo.
2. Identificar los requisitos y/o limitaciones de implementar un sistema basado en sensores inerciales para estudiar cómo los comportamientos visuales se asocian a comportamientos de conducción.

Para lograr lo anterior, y mediante el análisis de trabajo relacionado que se realizó en el Capítulo 2, se determinó que las variables asociadas a la atención del conductor son la *cantidad de vistazos* y la *duración de la mirada* hacia los PAV, las cuales se obtienen con el proceso explicado en la sección 3.3. Por otro lado, las variables del comportamiento de la conducción son aquellas asociadas al contexto del mismo, y se monitorizó dos de ellas: la *velocidad* a la que se conduce y *tipo de camino* por el que se conduce, el cual es clasificado en bulevares y áreas residenciales.

Para cumplir con lo anterior, se desarrolló un sistema de recolección de datos (Figura 4.1) que cumple con los requerimientos establecidos durante el capítulo anterior, así como la funcionalidad de monitorizar variables asociadas a la velocidad y ubicación del vehículo para determinar el tipo de camino sobre el que se conduce. El diseño de este sistema consiste en tres componentes que a continuación se explican.



Figura 4.1. Arquitectura del sistema para la recolección de datos mediante el uso de sensores.

4.1. Orientación de la cabeza

Se utilizaron sensores inerciales para estimar la orientación de la cabeza del conductor, cuyos datos en crudo pueden ser procesados mediante diferentes técnicas para cuantificar la orientación y posición de un sistema de referencia móvil sobre un sistema de referencia fijo (Kok et al., 2017). Dichos sensores inerciales fueron acelerómetro y magnetómetro, los cuales, como se explicó en el capítulo anterior, miden la aceleración de los cuerpos, así como la dirección, fuerza y cambios relativos de un campo magnético en una ubicación particular, respectivamente.

Este componente se implementó con la plataforma Google Glass (*Google Glass*, n.d.), que consiste en un dispositivo portable tipo *smart glasses* (lentes inteligentes) que fue utilizada para recolectar los datos en crudo de los sensores inerciales embebidos en el dispositivo. Este cuenta con un *touchpad*, que fue utilizado para interactuar con los lentes mediante diversos gestos durante la recolección de datos. También incorpora un *display* para mostrar información al usuario frente a su ojo derecho (Figura 4.2a).




Figura 4.2. Google Glass: **a)** características externas, **b)** ejes ortogonales en el dispositivo.

Google Glass utiliza el sistema operativo Glass OS, basado en Android 4.4 (KitKat), el cual provee un API (*Application Programming Interface*, i.e., interfaz de programación de aplicaciones) para manipular los sensores de la plataforma. En este API se encuentra disponible un sensor de rotación, el cual es virtual y utiliza como entrada los datos en crudo de los sensores acelerómetro y magnetómetro para estimar la orientación de un cuerpo mediante ángulos de Euler en sus componentes X, Y, y Z (*Position Sensors / Android Developers*, n.d.).

Aun cuando el conductor trae puesto los sensores inerciales, el verdadero sistema de referencia móvil es el vehículo, ya que cualquier rotación sobre sus ejes ortogonales afecta directamente los del conductor. Esto no representa un problema para los movimientos de cabeceo y alabeo, puesto que los automóviles son incapaces de producirlos en circunstancias normales (a diferencia de un avión, que tiene libertad de movimiento en sus tres ejes), por lo que cualquier movimiento en los ejes lateral y longitudinal (Figura 4.2b) del dispositivo se interpreta que provienen de los cambios en la orientación de la cabeza del conductor. Esta situación cambia para el movimiento de guiñada, pues, aunque el conductor no gire la cabeza sobre su eje vertical, el vehículo sí lo hace cuando cambia de dirección. Por lo anterior, el ángulo de Euler para la inclinación en Z representa un cambio en la orientación del vehículo y de la cabeza del sujeto, por lo que se descarta como variable predictora (Figura 4.3a). Eliminar una variable predictora podría reducir la precisión del algoritmo clasificador, el cual será evaluado en una sección posterior para cuantificar este efecto.

Se desarrolló una aplicación mediante Android Studio (*Android Studio and SDK Tools*, n.d.), la cual se desplegó sobre la plataforma Google Glass y contiene al componente de orientación de la cabeza. Este componente cuenta con dos modos de uso para la recolección de datos:

1. Estático: Debido a que el Componente de Inferencia de PAV utiliza k-NN como algoritmo de clasificación y este a su vez requiere de un conjunto de datos de entrenamiento, este modo de uso recolecta los valores de los ángulos de inclinación de la cabeza en los movimientos cabeceo y alabeo, y permite que el investigador los relacione a etiquetas que corresponden a los PAV. Las etiquetas utilizadas fueron S (del inglés “spot”), más un número asignado a cada PAV, utilizando los que se establecieron en el capítulo anterior. Por seguridad, este modo debe ser utilizado únicamente cuando el vehículo está estacionado. Para su operación, primeramente, mediante el gesto *swipe* se selecciona la etiqueta que se asociará a los ángulos de Euler producidos por la rotación de la cabeza. Al visualizarse la etiqueta en la pantalla del Google Glass, debe confirmarse mediante un *tap*. Enseguida inicia la recolección de datos, lo que el usuario podrá visualizar en pantalla, y podrá detener mediante el gesto *tap*. Esta recolección de datos se realiza a una tasa de 50 Hz, la cual es recomendada por el fabricante para realizar muestreos sobre el movimiento de la cabeza (*Locations and Sensors*, n.d.). Para cambiar de etiqueta se debe ejecutar un gesto *swipe* hacia abajo, lo cual regresará al usuario a la pantalla de selección de PAV. El procedimiento anterior, se resume en la Figura 4.3b.
2. Dinámico: Este modo debe ser usado mientras el vehículo se encuentra en movimiento y se utiliza para registrar los ángulos de Euler producidos por la rotación de la cabeza con su respectivo *timestamp* en cada lectura, con una tasa de 50 Hz. Los datos recolectados en esta modalidad son la entrada para el Componente de Inferencia, el cual clasificará los valores de Euler X y Euler Y como un PAV.

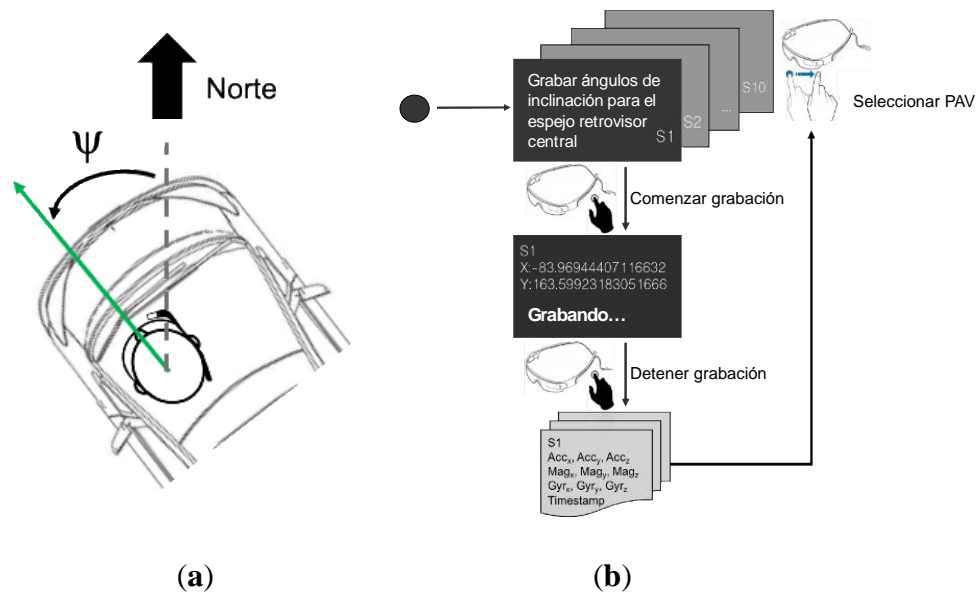


Figura 4.3. Componente de Orientación de la Cabeza en modo estático: **a)** al ser afectada por el movimiento del vehículo, se descarta la lectura del ángulo ψ , **b)** procedimiento para generar el conjunto de datos de entrenamiento mediante Google Glass.

4.2 Contexto de la conducción

Este componente fue implementado para la plataforma Android y se ejecuta sobre un dispositivo móvil (teléfono celular o tableta) para grabar los datos relacionados al contexto de la conducción. Como se muestra en la Figura 4.1, este componente incluye el uso de la cámara de video para registrar los comportamientos del conductor a lo largo del recorrido, el GPS para obtener la ubicación y velocidad del vehículo. El video es grabado de manera continua y cada *frame* incluye su *timestamp*, esto con la intención de comparar si la predicción arrojada por el componente de *Inferencia de PAV* en ese mismo instante (o uno muy cercano, empatando sus *timestamps*) coincide con lo registrado en el video, a manera de validación visual. La velocidad de manejo y ubicación también son muestreados a una tasa de 50 Hz y van acompañados de su respectivo *timestamp*, el cual es utilizado para enlazar los datos de este componente con los que se registran mediante el componente de *Orientación de la cabeza* en modo dinámico.

4.3 Inferencia de los PAV

El clasificador k-NN fue implementando mediante un archivo *script* en MATLAB versión 2018b, ya que por limitaciones de la plataforma Google Glass este procedimiento no puede ser llevado a cabo en el dispositivo.

Antes de utilizar el componente *Orientación de la cabeza* en modo dinámico, se realizaron pruebas para determinar los parámetros en el clasificador k-NN.

4.4 Desempeño del clasificador k-NN

Para encontrar cuales parámetros en el algoritmo de k-NN producen una mejor tasa de clasificación, se llevó a cabo un experimento con datos de entrenamiento obtenidos de dos sujetos. Este experimento ayudó a seleccionar los valores óptimos para el número de vecinos cercanos contra los cuales comparar la nueva observación, conocido como k , y la métrica para medir la similitud, o *distancia*, contra las instancias capturadas en la etapa de entrenamiento. Al ser dos parámetros los cuales se desean determinar, se probó una cuadrícula de posibilidades, la cual está conformada de la siguiente manera:

- Parámetro k : 3, 5, 7, 9 y 11 vecinos cercanos. Se considera una buena práctica utilizar una cantidad impar de vecinos para el valor en k puesto que así se evitan empates entre clases, y a su vez utilizar más de 1 vecino cercano.
- Parámetro similitud: Se utilizaron las técnicas para estimar distancias más utilizadas para k-NN, entre las que están manhattan, chebychev, euclidiana y minkowski.

Los datos fueron recolectados utilizando el componente *Orientación de la cabeza* en modo estático, donde se pidió a los sujetos que observaran cada PAV durante 10 segundos. Una vez obtenidos los datos de entrenamiento para cada sujeto se realizaron las pruebas para determinar el valor del parámetro k y de la técnica para estimar la distancia. Para estas pruebas se utilizó la técnica de evaluación *10-fold cross-validation*. Se identificó la mejor combinación de ambos parámetros con base en el menor porcentaje de clasificaciones erróneas. Los resultados de esta evaluación se observan en la Tabla 4.1, la cual muestra que la mejor combinación de parámetros se produjo al utilizar $k = 3$ y *distancia* euclidiana en ambos participantes, con una tasa de error en la clasificación de 0.00334 (i.e., 0.334%). La elección de dichos valores garantiza una menor tasa de clasificación errónea y, por lo tanto,

una mayor precisión. Con una precisión mayor al 95%, se considera, además, que el uso de 2 variables predictoras es viable para estimar la orientación de la cabeza.

Tabla 4.1. Tasas¹ de clasificación errónea para cada combinación de parámetros

Distancia	Participante 1					Participante 2				
	$k = 3$	$k = 5$	$k = 7$	$k = 9$	$k = 11$	$k = 3$	$k = 5$	$k = 7$	$k = 9$	$k = 11$
euclidiana	0.334	0.493	0.509	0.652	0.604	0.311	0.476	0.497	0.621	0.663
chebychev	0.382	0.620	0.525	0.700	0.763	0.373	0.580	0.580	0.683	0.745
manhattan	0.334	0.557	0.557	0.668	0.716	0.331	0.538	0.580	0.725	0.766
minkowski	0.366	0.588	0.604	0.763	0.732	0.373	0.518	0.518	0.621	0.683

¹expresadas en porciento

4.5 Diseño del estudio de factibilidad

Con base en los resultados de la evaluación del clasificador, se procedió a planear el diseño de un estudio que permitiera alcanzar los objetivos planteados al inicio de este capítulo.

4.5.1 Técnicas de reclutamiento y criterios de elegibilidad

Se reclutaron estudiantes de la Universidad Autónoma de Baja California, Campus Mexicali. Para ser elegibles, los participantes debían poseer licencia de manejo válida, contar con vehículo propio, y tener una agudeza visual 20/40 con ambos ojos, medida mediante la prueba de agudeza visual de Snellen (*All About the Eye Chart - American Academy of Ophthalmology*, n.d.). Antes de comenzar con el estudio, cada participante firmó un consentimiento informado, el cual es un procedimiento mediante el cual se garantiza que el sujeto ha expresado voluntariamente su intención de participar en la investigación, después de haber comprendido su propósito y extensión. A su vez, en el consentimiento informado se agregó un apartado donde los investigadores se comprometen a tratar con total confidencialidad cualquier dato o grabación recabada de los participantes.

4.5.2 Etapas del estudio

El experimento se llevó a cabo en tres etapas. La primera etapa consistió en una sesión de recolección de datos de entrenamiento mediante el componente *Orientación de la cabeza* en modo estático. Los participantes se colocaron los lentes inteligentes Google Glass y fueron instruidos en voltear hacia cada PAV mientras se registraban los ángulos de

inclinación de la cabeza correspondientes a Euler X y Euler Y. De este modo se obtuvo un conjunto de datos de entrenamiento para cada sujeto.

La segunda etapa consistió en una sesión de conducción, la cual incluyó caminos arteriales y residenciales, propiamente definidos en la jerarquía de caminos (*Chapter 3: Functional Classification - Flexibility - Publications - Environment - FHWA*, n.d.). Los caminos arteriales son vías de alta velocidad que pueden contener una alta cantidad de vehículos. En la ciudad de Mexicali, Baja California, México, dichos caminos son conocidos como bulevares y la velocidad máxima permitida es de 60 km/h. Los caminos residenciales tienen el menor límite de velocidad, el cual corresponde a 40 km/h. Todos los participantes condujeron la misma ruta y por lo tanto la misma distancia, la cual se conformó de 3.1 km de calles residenciales y 3.9 km de camino en bulevares. Para esta etapa se utilizaron en conjunto los componentes *Contexto de la conducción y Orientación de la cabeza* en modo de recolección dinámica.

La tercera etapa consistió en procesar y analizar los datos recolectados durante las etapas anteriores. El procesamiento de datos se llevó a cabo, a su vez, en tres partes:

- **Indexación:** La variable *timestamp*, registrada de manera simultánea en cada lectura de los componentes de *Contexto de la conducción y Orientación de la cabeza*, fue utilizada para empear los registros de los PAV, velocidad de conducción y ubicación del vehículo.
- **Clasificación:** Los ángulos de Euler producidos por la orientación de la cabeza son clasificados como PAV mediante el *Componente de Inferencia de PAV*. Cada inferencia de los PAV incluye su *timestamp*, el cual acompañaba a las variables predictoras utilizadas como entrada para obtener dicha etiqueta.
- **Preparación:** Como salida del paso anterior, cada muestra resultante consta del PAV inferido, la velocidad del vehículo y el tipo de camino sobre el que se conducía en ese instante de tiempo, la cuál tiene una duración de 0.02 segundos. Las entradas consecutivas para un mismo PAV pueden ser entonces agrupadas y, mediante el uso de sus *timestamps*, se puede saber cuánto tiempo fue observado cada PAV. En relación a lo anterior, el conteo de dichos agrupamientos arroja la cantidad de veces que cada PAV fue observado.

Los datos procesados de cada sujeto son agregados a un repositorio de datos de comportamiento. Una vez añadidos los comportamientos de todos los participantes se procedió a analizarlos mediante el uso de estadística descriptiva tal como estimación de medias y desviación estándar (*Social Science Statistics*, n.d.). Las variables analizadas fueron:

- Velocidad del vehículo.
- Tipo de camino, el cual podía ser arterial o residencial.
- Cantidad de vistazos, definida por el número de veces que la mirada del conductor observó cada PAV (*eyes off-on-off*).
- Duración de la mirada, estimando el tiempo (en segundos) que la mirada del conductor se mantuvo al observar cada PAV.

4.6 Resultados

4.6.1 Datos de los participantes

Quince (15) estudiantes fueron reclutados, basados en los criterios de elegibilidad y técnicas de reclutamiento, siendo estos 12 hombres y 3 mujeres, con edades entre los 20 y 29 años de edad ($M = 22.4$, $SD = 2.3$). La velocidad media de los participantes para todo el recorrido estuvo en el rango de los 16.38 hasta los 30.42 km/h ($M = 20.70$, $SD = 3.85$). Por tipo de camino, la velocidad media en caminos de tipo residencial varió desde los 12.50 hasta los 24.87 km/h; mientras que, en los caminos de tipo arterial, donde generalmente se conduce a velocidades más altas, la media de los participantes varió desde los 21.51 hasta los 37.03 km/h.

Aplicando la técnica de validación *10-fold cross-validation* sobre los conjuntos de datos de entrenamiento, se obtuvo una media en la tasa de error que varió desde el 0 hasta 0.46% ($M = 0.20$, $SD = 0.13$). Existen varios razonamientos del por que ésta media fue menor que la obtenida durante los experimentos donde se determinaron los parámetros para k y la métrica de *distancia* para el clasificador ($M = 0.32$, $SD = 0.01$). Uno de ellos puede ser la variabilidad inter-sujeto respecto a la realización de las pruebas, la cual puede verse afectada por diversos factores, como el sentirse observados. Otra razón puede ser la cantidad de conjuntos de datos de entrenamiento utilizados en las verificaciones: si bien

cada uno de ellos contiene aproximadamente la misma cantidad de instancias, se utilizaron 15 para esta verificación en comparación de los 2 durante la experimentación antes mencionada. Algunas de sus características demográficas son mostradas en la Tabla 4.2.

Tabla 4.2. Características de los participantes

Participante	Datos Demográficos		Precisión de k-NN en Modo Estático		Datos de Conducción Recolectados en Modo Dinámico	
	Genero	Edad	Tasa de Error (%)	Precisión (%)	Velocidad ¹ <i>M (SD)</i>	Velocidad ¹ (<i>M</i>) en caminos Residenciales/Arteriales
P1	Hombre	21	0.11	99.89	17.45 (18.17)	14.19/21.51
P2	Hombre	21	0.20	99.80	20.30 (18.33)	15.88/25.33
P3	Hombre	20	0.25	99.75	17.11 (16.70)	12.50/33.59
P4	Hombre	22	0.29	99.71	17.74 (18.61)	12.88/32.70
P5	Hombre	21	0.46	99.54	22.03 (20.18)	15.57/32.60
P6	Hombre	25	0.12	99.88	19.36 (19.90)	15.26/29.57
P7	Hombre	29	0.46	99.64	20.62 (19.28)	16.01/33.14
P8	Hombre	22	0.12	99.96	19.90 (18.67)	17.42/22.34
P9	Hombre	22	0.20	99.80	26.18 (23.21)	21.59/31.08
P10	Mujer	21	0.30	99.70	16.78 (17.47)	12.38/30.28
P11	Hombre	23	0.20	99.80	24.25 (21.34)	18.15/34.30
P12	Mujer	21	0.00	100	20.79 (18.73)	15.57/37.03
P13	Mujer	22	0.14	99.86	30.42 (22.32)	24.87/36.70
P14	Hombre	25	0.02	99.98	16.38 (17.86)	12.72/21.89
P15	Hombre	21	0.15	99.85	21.18 (18.06)	16.84/31.74

¹ velocidad en km/h

4.6.2 Cantidad de vistazos y jerarquía del camino

La Tabla 4.3 presenta la cantidad de vistazos a cada PAV dentro de la cabina, obtenidos a través del componente de *Inferencia de PAV*. Sin tomar en cuenta el tipo de camino, el PAV correspondiente al *camino* fue el más frecuentado (1322), seguido del *espejo retrovisor central* (1141) y *pasajero* (922). Este mismo orden se conserva aun si se toma en cuenta el tipo de camino. Las grabaciones de video confirman que los sujetos tendían a voltear hacia el PAV del *pasajero* al platicar con él, lo cual puede explicar por que este PAV fue más incidido que los otros dos *retrovisores*, el *tablero de control* y el área de *radio/clima*.

En general, la frecuencia de la mirada a todos los PAV fue menor cuando se conducía en caminos arteriales (bulevares) que en caminos residenciales. Se deduce que los participantes tendían a limitar sus interacciones con los puntos no críticos al conducir

cuando se manejaba en bulevares porque estos demandan una mayor atención visual en el *camino*.

Es especialmente evidente que el sistema de *radio/clima* fue el más ignorado por todos los participantes mientras se conducía en caminos arteriales. La visualización de los comportamientos respecto a la cantidad de vistazos por tipo de camino puede observarse en la Figura 4.4.

Tabla 4.3. Cantidad de vistazos a cada PAV

		Camino	Retrovisor Central	Retrovisor Izquierdo	Retrovisor Derecho	Tablero de Control	Radio/Clima	Pasajero
Residencial	Sum	901	748	222	347	111	44	618
	M	60.07	49.87	14.80	23.13	7.40	2.93	41.20
	SD	41.24	34.63	14.00	23.65	10.02	6.47	31.04
Arterial (Boulevard)	Sum	310	269	68	131	27	4	255
	M	22.14	19.21	4.86	9.36	1.93	0.29	18.21
	SD	32.08	31.39	8.47	10.92	3.26	1.25	19.63
Total	Sum	1322	1141	311	485	142	52	922
	M	88.13	76.07	20.73	32.33	9.47	3.47	61.47
	SD	70.05	65.17	20.45	32.62	13.16	6.81	49.75

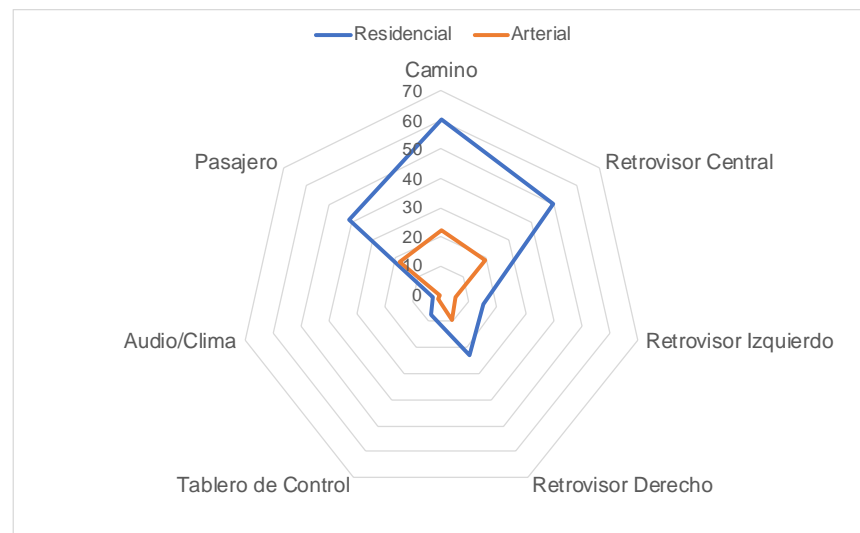


Figura 4.4. Comparativa del promedio de cantidad de vistazos a cada PAV, por tipo de camino.

La Tabla 4.4 presenta la duración de los vistazos a cada punto de atención visual dentro de la cabina, obtenidos a través del componente de *Inferencia de PAV*. Sin tomar en cuenta el tipo de camino, el PAV correspondiente al *camino* fue el que se observó por más tiempo (289.27 s), seguido del *pasajero* (92.46 s) y *retrovisor central* (88.54 s).

Considerando el tipo de camino, los PAV correspondientes al *tablero de control* y *radio/clima* son los que recibieron menor tiempo de atención visual, lo cual también se ve reflejado en los totales; esto puede deberse a que no se trata de áreas críticas (o necesarias) con las que el conductor deba interactuar para tener un viaje seguro, como sí lo son los tres PAV correspondientes a retrovisores. Sin embargo, el área del *pasajero* si fue observado por mas tiempo en comparación con los *retrovisores izquierdo y derecho*, independientemente del tiempo de camino. Si bien fue menos frecuentado que el *espejo retrovisor central*, lo cual se presentó en la Tabla 4.3, la media del tiempo que los conductores asignaron a cada vistazo en este PAV es mayor que cuando se observó dicho retrovisor. Eso se confirmó mediante las grabaciones de video, donde se pudo apreciar que, después del tiempo asignado a interactuar visualmente con el *camino*, le sigue en duración el PAV del *pasajero* debido a las interacciones que estos últimos tuvieron con el conductor (e. g. plática). La visualización de los comportamientos respecto a la duración de la mirada por tipo de camino puede observarse en la Figura 4.5.

Tabla 4.4. Duración de vistazos a cada PAV¹

		Camino	Retrovisor Central	Retrovisor Izquierdo	Retrovisor Derecho	Tablero de Control	Radio/Clima	Pasajero
Residencial	<i>Sum</i>	133.54	48.63	30.66	33.36	18.56	6.71	47.17
	<i>M</i>	8.90	3.24	2.04	2.22	1.24	0.45	3.14
	<i>SD</i>	10.13	2.09	2.28	1.50	1.03	0.59	1.51
Arterial (Boulevard)	<i>Sum</i>	155.73	39.91	29.03	47.58	14.53	7.82	45.29
	<i>M</i>	10.38	2.66	1.94	3.17	0.97	0.52	3.02
	<i>SD</i>	8.12	2.18	2.63	3.60	1.17	1.21	2.49
Total	<i>Sum</i>	289.27	88.54	59.69	80.94	33.09	14.52	92.46
	<i>M</i>	9.64	2.95	1.99	2.70	1.10	0.48	3.08
	<i>SD</i>	9.05	2.12	2.42	2.76	1.09	0.94	2.02

¹duración en segundos




Figura 4.5. Comparativa del promedio de la duración de la mirada, en segundos, a cada PAV, por tipo de camino.

4.7 Conclusiones

Para llevar a cabo el estudio de factibilidad se desarrolló una arquitectura de recolección de datos mediante el uso de sensores, el cual integra múltiples componentes para el estudio de comportamientos de manejo en condiciones naturalistas. Los resultados sugieren que la cantidad de vistazos hacia todos los PAV dentro de cabina se ve reducida cuando se conduce en caminos de alta velocidad, comparado con la conducción en caminos de más baja velocidad como lo son las zonas residenciales. De manera general, conforme la velocidad de manejo aumenta, la interacción visual del conductor, expresada en cantidad de vistazos y la duración de estos, se ve reducida hacia todos aquellos PAV que no forman parte del camino. Los resultados anteriores evidencian cómo la velocidad del vehículo y tipo del camino tienen influencia en los comportamientos visuales de los conductores, lo cual responde la Pregunta de Investigación 1 (“¿Cómo los comportamientos visuales se relacionan a variables del contexto de la conducción?”).

El video grabado mediante el componente de *Contexto de la conducción*, el cual fungió como *ground truth* (información obtenida por observación directa del fenómeno, o evidencia empírica), fue utilizado para verificar la información obtenida mediante el componente de *Inferencia de PAV* y validar la veracidad de los resultados. Sin embargo, se considera que incluir más sujetos en el estudio ayudaría a confirmar los resultados

obtenidos. A su vez, para responder la Pregunta de Investigación 2 (“¿Cómo difieren los comportamientos visuales entre grupos de edad?”) debe incluirse otros grupos de edad; por lo que para abordar esta pregunta se realizó el estudio presentado en Capítulos 6 y 7 el cuál incluyó adultos jóvenes y adultos mayores que utilizaron el sistema.

4.7.1 Limitaciones

Las interacciones de los sujetos de prueba con el investigador durante la etapa de la conducción no fueron controladas, lo que resulta en que el número de estas variaran por participante, y, por lo tanto, la homogeneidad en su cantidad y duración.

Una limitación del sistema es su incapacidad de cuantificar el movimiento de la cabeza del conductor en su eje vertical, o guiñada, mientras el vehículo se encuentra en movimiento. Si bien los ángulos de Euler para los movimientos de cabeceo y alabeo proporcionaron los datos suficientes para que el clasificador obtuviera un buen desempeño durante la etapa de validación, se estima que esta precisión podría ser menor en práctica, pues observar un PAV implica el movimiento de la cabeza sobre sus tres ejes. Este problema se puede abordar utilizando una cámara, la cual, auxiliada de técnicas de visión artificial, se utilizará para realizar seguimiento de caras (*face-tracking*) y cuantificar la orientación de la cabeza.

A su vez, la plataforma Google Glass tiene un poder de procesamiento que resulta insuficiente para llevar a cabo clasificaciones en tiempo real, aun con algoritmos sencillos de implementar (tales como k-NN, así sea utilizando pocos vecinos cercanos y métricas de similitud fácilmente calculables). Debido a esto, fue estrictamente necesario grabar mediante video cada uno de los viajes y consultarlos de manera manual para validar los comportamientos obtenidos por el componente de *Inferencia de PAV*. La inferencia en tiempo real ayudaría a reducir la dependencia sobre dichas grabaciones, pues resultaría sencillo verificar la precisión del clasificador apenas obtenido el conjunto de datos de entrenamiento.

Otra limitación de la plataforma es que esta tiende a sobrecalentarse, lo cual puede resultar en ligeras molestias para algunos sujetos de prueba y reducción tanto en la vida útil de la batería como en la tasa de muestreo del sensor de rotación; esto último debido a que,

en caso de calentamiento, la plataforma busca proteger sus componentes electrónicos y toma la medida de reducir la tasa de muestreo de sensores físicos y virtuales que estén siendo utilizado en este momento, hasta enfriarse nuevamente. Google Glass carece también de acceso directo a su sistema de almacenamiento interno, por lo cual se dificulta la extracción de los datos recolectados durante los estudios. En el siguiente capítulo se presenta cómo se rediseñó e implementó el sistema para abordar estas limitaciones.

Capítulo V

Diseño del sistema

Concluido el estudio de factibilidad fueron identificadas algunas limitaciones en el sistema de recolección de datos, las cuales pueden ser usadas como áreas de oportunidad para mejorar la robustez y precisión del mismo.

5.1 Requerimientos

Para la siguiente iteración de la plataforma de recolección de datos mediante el uso de sensores se identificaron los siguientes requerimientos:

- Debido a las limitaciones anteriormente mencionadas de la plataforma Google Glass, utilizar otro dispositivo portable que incluya sensores inerciales para cuantificar la inclinación de la cabeza en sus movimientos de cabeceo y alabeo mediante ángulos de Euler.
- Usar una cámara para cuantificar, en ángulos de Euler, la inclinación de la cabeza en su movimiento de guiñada.
- Ambos dispositivos deberán realizar muestreos con una frecuencia mínima de 50 Hz – tasa recomendada en la detección de los movimientos de la cabeza– de manera ininterrumpida y con autonomía de 1 (una) hora, duración aproximada de la recolección de datos del estudio.
- Desarrollo de un componente que tome de manera simultánea los muestreos de los dispositivos señalados anteriormente y los convierta en una sola señal.
- Desarrollo de un componente para clasificar en tiempo real las lecturas combinadas de los sensores inerciales y cámara, del cual su salida será el PAV al cual el sujeto está dirigiendo su atención visual en ese momento de acuerdo a la postura de la cabeza.

- Desarrollo de un componente que monitoree datos relacionados al contexto del vehículo (velocidad de manejo, ubicación), en sincronía con el PAV inferido por el componente clasificador.

5.2 Diseño funcional

5.2.1 Arquitectura del sistema

Con base en los requerimientos establecidos anteriormente, se desarrolló una nueva versión del sistema de recolección de datos, cuya arquitectura puede observarse en la Figura 5.1. Sus componentes serán explicados a continuación.

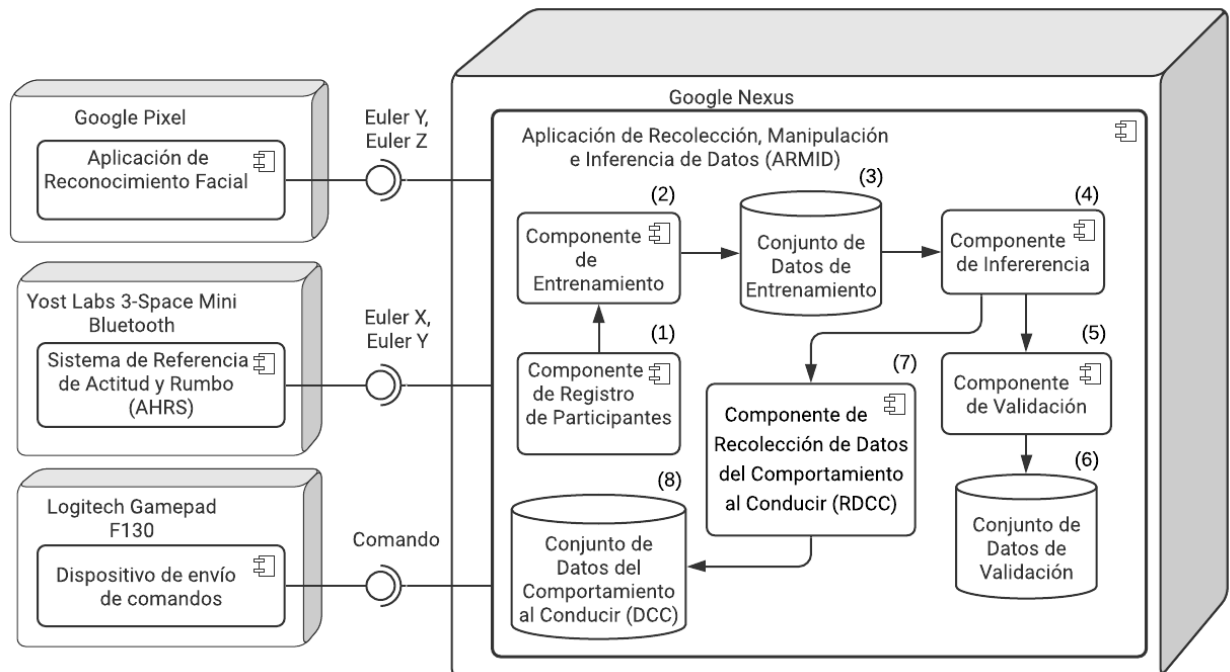


Figura 5.1. Arquitectura de la segunda versión del sistema portable para la recolección de datos.

5.2.2 Sistema de Referencia de Actitud y Rumbo (AHRS)

El *Sistema de Referencia de Actitud y Rumbo (AHRS, Attitude and Heading Reference System)* combina y procesa las lecturas de sensores inerciales para proveer información sobre los movimientos de cabeceo y alabeo cuerpo donde se fija, correspondientes a los ángulos de Euler X y Y. Este sistema consiste del dispositivo Yost

Labs 3-Space Mini Bluetooth (*3-Space™ Mini Bluetooth LE Inertial Motion Sensor - Yost Labs*, n.d.), el cual, además de ser un AHRS, funciona también como unidad de medición inercial (IMU). El dispositivo ya colocado, así como sus ejes ortogonales, son ilustrados en la Figura 5.2a.




Figura 5.2. Componentes para cuantificar la orientación de la cabeza: **a)** Sistema de Referencia de Actitud y Rumbo, **b)** Aplicación de Reconocimiento Facial.

Este dispositivo, con 9 gramos de peso y dimensiones de 30mm x 30 mm x 13mm, es fácilmente portable en la cabeza del conductor. Por ser diseñado específicamente para recolección de datos, tiene una batería con 4 horas de duración y soporta muestreos de hasta 1750 Hz, sin llegar a calentarse durante su operación. Se comunica de manera inalámbrica con otros dispositivos mediante el protocolo Bluetooth 4.0. Los datos recolectados a través de este sensor pueden ser obtenidos en formato *crudo* con base en las lecturas de tres sensores inerciales (giroscopio, acelerómetro y magnetómetro), o procesados en formato de cuaterniones, matriz de rotación, ángulos de Euler, y notación axial-angular.

5.2.3 Aplicación de Reconocimiento Facial (ARF)

Se desarrolló una aplicación con la librería ML Kit for Firebase (*ML Kit for Firebase*, n.d.), para estimar en tiempo real la orientación de la cabeza utilizando la cámara

de un dispositivo Android. La librería aplica técnicas de visión artificial para detectar rostros mediante sus características faciales como ojos, nariz y boca (*Face Detection* / *Firebase*, n.d.). Cuando un rostro es detectado, con ML Kit se extrae la orientación de la cabeza en alabeo y guiñada, describiéndola mediante los ángulos de Euler Y y Z (Figura 5.2b).

El ambiente de desarrollo utilizado para esta aplicación incluyó el IDE Android Studio (*Android Studio and SDK Tools*, n.d.) versión 3.5, con el API 16 (Jelly Bean) como versión mínima soportada. Dicha aplicación contiene como dependencias las siguientes librerías:

- *firebase-ml-vision* versión 24.0.1, para detectar rostros
- *firebase-ml-vision-face-model* versión 19.0.0, contiene modelos de entrenamiento proporcionados por Google para detectar rostros
- *cameraview* versión 2.6.1, facilita la captura y procesamiento de video, específicamente el análisis cuadro por cuadro de video capturado en tiempo real y al cual se le puede aplicar el reconocimiento de rostros provisto por las dos librerías anteriores en combinación.

La *Aplicación de Reconocimiento Facial* (ARF) fue desarrollada para un teléfono celular Google Pixel. Se utilizó el protocolo Bluetooth 4.0 de dicho dispositivo para transmitir de manera inalámbrica las lecturas de los ángulos de Euler Y y Z en cada *frame* de video hacia el componente *Aplicación de Recolección, Manipulación e Inferencia de Datos* (ARMID).

5.2.4 Dispositivo para envío de comandos

Si bien la pantalla táctil del dispositivo donde se despliega ARMID es el principal método de entrada para interactuar con la interfaz gráfica de sus sub-componentes, dos de ellos, y de los cuales se hará mención enseguida, requieren que el operador de la tableta Nexus preste atención al camino y a su vez haga anotaciones en el dispositivo, por lo que resulta ineficiente (además de una distracción) tener que prestar atención a dos lugares de manera intercalada.

Por este motivo, al sistema se incorporó un dispositivo para envío de comandos (referido también como *gamepad*), el cual, como su nombre lo indica, envía señales a los sub-componentes de ARMID, las cuales se interpretan como *taps* en los elementos de sus interfaces gráficas.

Este componente se configura para usarse en dos etapas del estudio. En la etapa de validación, los controles del *gamepad* fueron mapeados para recolectar datos de *ground truth* (Figura 5.3a). En este sentido, el *gamepad* fue la interfaz de usuario que permitió registrar en tiempo real los PAV que el sujeto observa mientras conduce. Los datos recolectados de este modo se utilizan para evaluar el desempeño del *Componente de Inferencia*.

El *gamepad* también se utiliza como una interfaz de usuario que facilita registrar datos durante la recolección de datos del comportamiento al conducir. Para esta etapa, se designó a una persona, conocida como “Anotador”, el cual utilizó el *gamepad*, mientras el sujeto conducía, para registrar información en la tableta Nexus como, si el conductor giró el vehículo hacia la derecha o izquierda, se detuvo en semáforo en rojo, cambió de carril, entre otros (Figura 5.3b). Ambas etapas serán explicadas a detalle en secciones posteriores.



Figura 5.3. Logitech Gamepad F310: **a)** Mapeo de controles para el Componente de Validación, **b)** Mapeo de controles para el Componente de Recolección de Datos del Comportamiento al Conducir.

Cualquier *gamepad* que cuente con interfaz USB (*Universal Serial Bus*) puede ser utilizado como dispositivo de envío de comandos, el cual es conectado a la tableta a través

de un adaptador OTG (*USB-On-The-Go*). Para este estudio se utilizó el mando Logitech Gamepad F310.

5.2.5 Aplicación de Recolección, Manipulación e Inferencia de Datos (ARMID)

Este componente se encarga de recibir y manipular las señales emitidas por los componentes AHRS y ARF, con la finalidad de generar conjuntos de datos de entrenamiento y del comportamiento al conducir.

Específicamente, ARMID contiene los siguientes sub-componentes:

1. *Componente de Registro de Participantes*, donde se les solicita a los sujetos del estudio su nombre, género y edad, así como firmar un consentimiento informado.
2. *Componente de Entrenamiento*, utilizado para generar los datos de entrenamiento de los sujetos del estudio.
3. *Conjunto de Datos de Entrenamiento*, el cual es un repositorio donde se almacenan de manera local los datos de entrenamiento producidos por el *Componente de Entrenamiento*.
4. *Componente de Inferencia*, cuya función es utilizar un clasificador k-NN junto al *Conjunto de Datos de Entrenamiento*, de tal manera que al recibir lecturas de los dispositivos AHRS y ARF, infiera el PAV observado por el sujeto en ese instante.
5. *Componente de Validación*, del cual se hace uso durante la etapa de validación del sistema, para registrar en sincronía el PAV obtenido mediante la invocación al *Componente de Inferencia* y el que el sujeto de prueba indique que está observando en ese momento.
6. *Conjunto de Datos de Validación*, que consiste en un repositorio integrado por los datos de validación producidos por el *Componente de Validación*.
7. *Componente de Recolección de Datos del Comportamiento al Conducir (RDCC)*, que invoca al *Componente de Inferencia* para registrar los PAV inferidos por este último, junto a otras variables producidas directamente por el componente, como la ubicación y velocidad del vehículo. La colección de los registros generados por este componente, para todos los sujetos, conforma el repositorio *Conjunto de Datos del Comportamiento al Conducir (CDCC)*.

ARMID se desarrolló mediante el IDE Android Studio 3.5, utilizando el API 19 (KitKat) como versión mínima soportada. Dicha aplicación fue desplegada en una tableta Google Nexus; pero cualquier dispositivo Android es capaz de ejecutar la aplicación si cuenta con los siguientes requisitos de hardware:

- Sensor GPS, requerido para conocer la ubicación y velocidad del vehículo
- Conexión a Internet, para subir los conjuntos de datos generados a la nube

ARMID recolecta las señales emitidas por los componentes AHRS y ARF para posteriormente combinarlas y transmitir las como una sola señal a los sub-componentes que la requieran para su operación. Esta señal se compone de 4 variables, las cuales describen la orientación de la cabeza en términos de ángulos de Euler, y son identificadas de la siguiente manera:

- X_{AHRS} : Ángulo de Euler X proveniente del componente AHRS
- Y_{AHRS} : Ángulo Euler Y proveniente del componente AHRS
- Y_{ARF} : Ángulo Euler Y proveniente del componente ARF
- Z_{ARF} : Ángulo Euler Z proveniente del componente ARF

La Figura 5.4 ilustra las interfaces de usuario (IU) de los diferentes sub-componentes del componente ARMID.

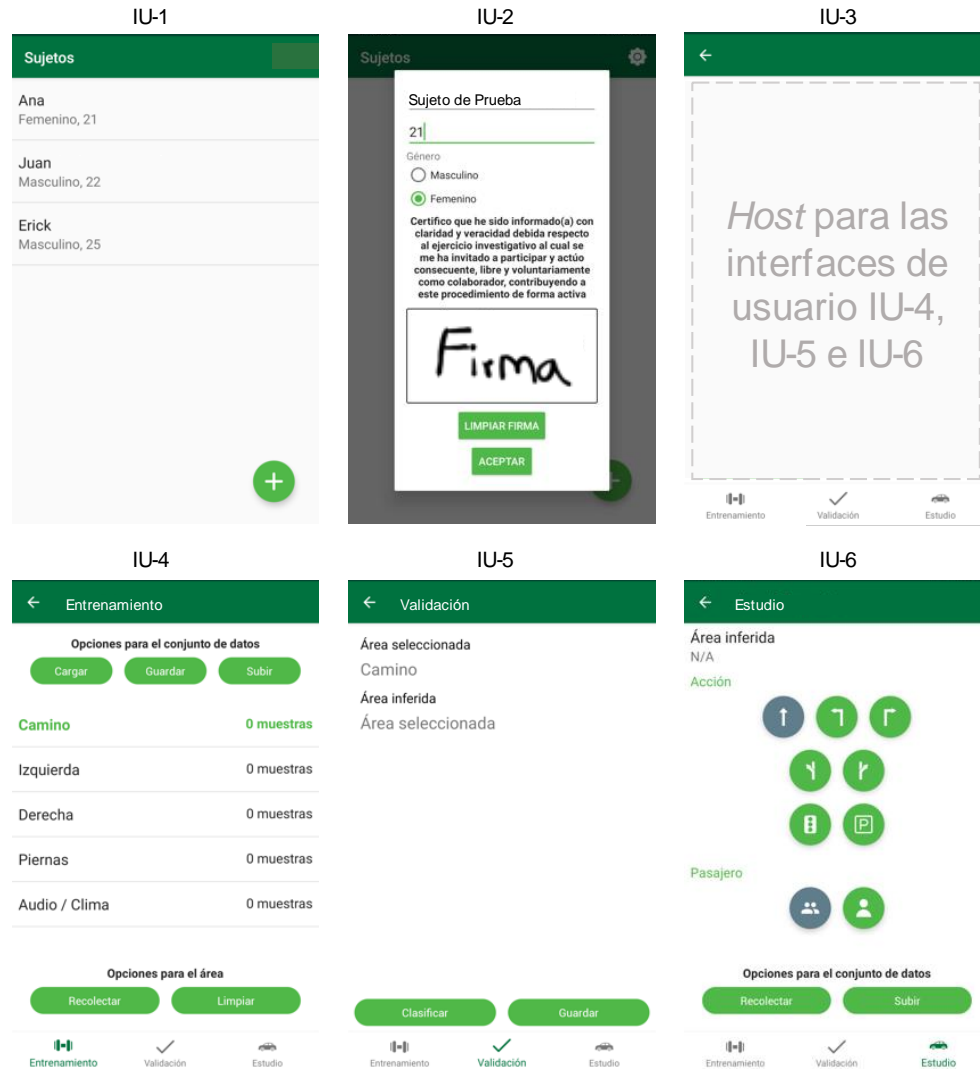


Figura 5.4. Navegación en la interfaz de usuario de la aplicación (ARMID).

Cuando se inicia la aplicación (ARMID), el usuario es llevado a la IU-1, la cual contiene la interfaz gráfica del *Componente de Registro de Participantes*, en la cuál se puede visualizar a los participantes registrados. Presionando el ícono “+” se presenta la IU-2, donde se puede registrar a un nuevo participante. A su vez, al seleccionar a uno de los participantes ya existentes en la UI-1, se presenta la IU-3, que en su parte inferior contiene íconos para invocar a las interfaces de usuario de los componentes de *Entrenamiento* (IU-4), *Validación* (IU-5) o *Recolección de Datos del Comportamiento al Conducir* (IU-6). Estos componentes y sus IU son explicados a continuación.

5.2.5.1 Componente de Registro de Participantes

Este componente fue utilizado para registrar los datos de los participantes del estudio y solicitar su firma en un formato de consentimiento informado (Figura 5.4 IU-2) que nos autorizaba a utilizar sus datos para propósitos del estudio y cuidando su privacidad. El formato de este consentimiento informado se muestra completo en el Apéndice A. Para acceder a la IU de los componentes *entrenamiento*, *validación*, y *RDCC*, es necesario seleccionar algún participante que haya sido dado de alta previamente, mediante este componente, lo cual se puede llevar a cabo a través del listado que se muestra en la Figura 5.4 IU-1.

5.2.5.2 Componente de Entrenamiento

El objetivo de este componente es generar un conjunto de datos de entrenamiento para cada sujeto, asociando los ángulos de Euler que se producen al orientar la cabeza hacia los PAV dentro de cabina. Para el estudio final se utilizaron los especificados en la Figura 5.5, los cuales difieren a los identificados en el estudio de factibilidad, permaneciendo intactos los correspondientes al *Camino*, *Retrovisor Izquierdo*, y *Radio/Clima*. Se removió el *Retrovisor Central*, ya que se observó en las grabaciones pasadas que eran contadas las ocasiones en las cuales los sujetos necesitaban levantar la cabeza para observarlo, y bastaba mover los ojos para este propósito. Por esto mismo, se removió el PAV de *Tablero de Control* en favor de agregar el PAV *Piernas*, relacionado al uso del teléfono celular. Debido a la confusión que podría ocurrir cuando el sujeto voltea a ver los PAV *Pasajero* y *Retrovisor Derecho*, por ubicarse ambos a la derecha del conductor, se decidió unificarlos como uno solo, ahora llamado *Derecha*. Para unificar términos, el *Retrovisor Izquierdo* pasó a llamarse *Izquierda*. Por último, debido a que el audio que se escucha en cabina puede no provenir únicamente de la radio, *Radio/Clima* se renombró a *Audio/Clima*.

El procedimiento para recolectar las instancias por PAV funciona en modo estático, es decir, con el automóvil estacionado. Durante la sesión, se solicita al sujeto de prueba que se siente en el área de conducir, mientras un anotador realiza los siguientes pasos para etiquetar los datos recolectados utilizando la interfaz de usuario de la Figura 5.6.




Figura 5.5. PAV dentro de cabina en la segunda versión del sistema.

PAV	Muestras
Camino	286 muestras
Izquierda	259 muestras
Derecha	291 muestras
Piernas	300 muestras
Audio / Clima	301 muestras

1. Lista de selección de PAV
 2. Cargar las lecturas de todos los PAV a memoria
 3. Guardar las lecturas de todos los PAV en el dispositivo
 4. Guardar las lecturas de todos los PAV en la nube
 5. Iniciar/detener las lecturas de los sensores, asociadas al PAV seleccionado
 6. Limpiar las lecturas en memoria, asociadas al PAV seleccionado

Figura 5.6. Acciones que se pueden realizar con los elementos (1-6) de la interfaz de usuario del Componente de Entrenamiento.

En caso de haber generado previamente un conjunto de datos de entrenamiento para el sujeto, el conjunto de datos puede ser traído de vuelta a memoria mediante el botón “Cargar” (Figura 5.6-2), lo cual hará que las instancias que se adquirieran a continuación sean añadidas en dicho conjunto. A continuación, se le pide al sujeto que oriente su cabeza hacia alguno de los PAV ilustrados en la Figura 5.5.

1. El anotador selecciona un PAV de los mostrados en Figura 5.6-1.

2. Para iniciar la recolección, el anotador selecciona el botón “Recolectar” (Figura 5.6-5), lo que hace que el *Componente de Entrenamiento* notifique a los componentes AHRS y AFR que le envíen sus lecturas de orientación de cabeza, las cuales recibirá, asociará con la etiqueta seleccionada en el paso 1 y enviará al repositorio de *Conjunto de Datos de Entrenamiento*.
3. Al registrar 250 instancias aproximadamente (5 segundos con tasa de 50 Hz), el anotador notifica a los componentes AHRS y AFR que se detengan (Figura 5.6-5). Mediante pruebas cuantitativas (Figura 5.7), se estableció que la inferencia en tiempo real puede llevarse a cabo con un tiempo de respuesta aceptable (2 milisegundos, el mismo tiempo que toma levantar una muestra) y una alta precisión (98%) cuando se usan aproximadamente 250 muestras por PAV. Este procedimiento deberá ser repetido hasta haberse registrado instancias para cada uno de los PAV.

La secuencia de los eventos anteriores puede ser apreciada en la Figura 5.8




Figura 5.7. Resultados de la prueba cuantitativa para establecer el número de instancias por clase en los conjuntos de datos de entrenamiento.

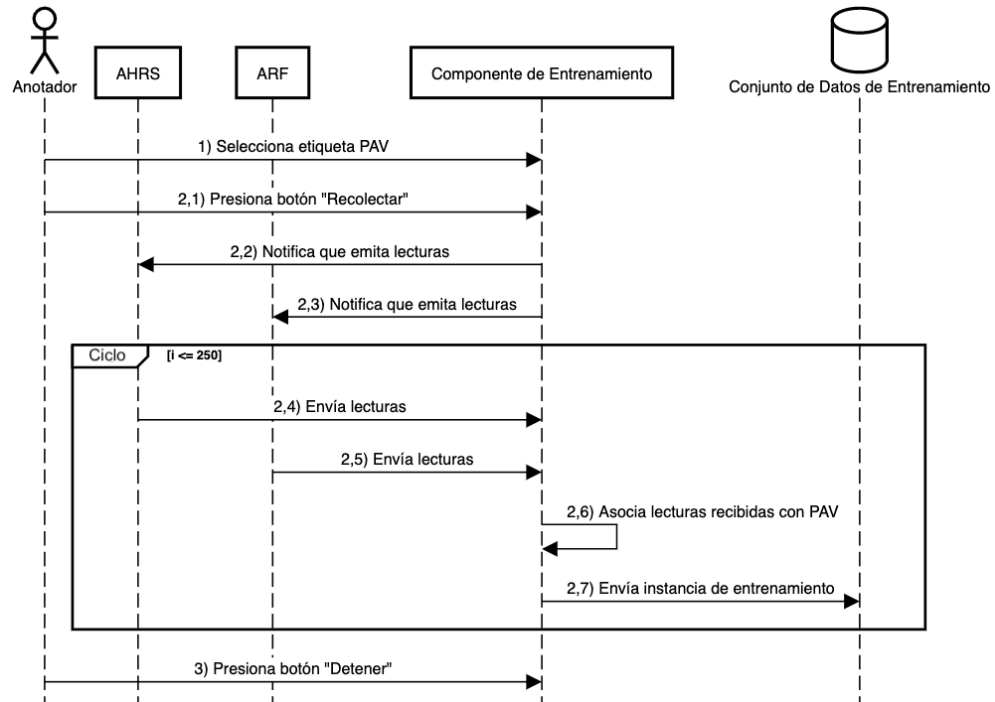


Figura 5.8. Diagrama de secuencia para generar el conjunto de datos de entrenamiento.

Cuando se han registrado todas las instancias, estas deberán ser escritas en la memoria del dispositivo mediante el botón “Guardar” (Figura 5.6-3). Si por algún motivo se desea desechar el conjunto de datos de entrenamiento, se presiona el botón “Limpiar” (Figura 5.6-6). Para extraer los datos del dispositivo, se presiona el botón “Subir” (Figura 5.6-4), el cual tomará el conjunto de datos de entrenamiento, los convertirá en un archivo con extensión CSV (*Comma-Separated Values*, Valores Separados por Coma), y será almacenado en la nube, dentro una instancia privada de Firebase Cloud Storage (*Cloud Storage* / *Firebase*, n.d.). La estructura de este conjunto de datos se ilustra en la Figura 5.9.

X_{AHRS}	Y_{AHRS}	Y_{ARF}	Z_{ARF}	CLASE
...
-0.23887	0.04264	16.156	1.177115	CAMINO
-0.23999	0.04265	16.13435	1.095086	CAMINO
0.28835	0.02064	-9.10953	3.401225	AUDIO/CLIMA
0.28841	0.02011	-10.4182	4.786786	AUDIO/CLIMA
...

Figura 5.9. Ejemplo de instancias almacenadas en Conjunto de Datos de Entrenamiento; la columna CLASE corresponde al PAV donde el conductor orientó la cabeza.

5.2.5.3 Componente de Inferencia

Este componente implementa el algoritmo k-NN para inferir el PAV al que el conductor dirige su atención mediante la lectura y clasificación de los ángulos de Euler proveniente de la orientación de su cabeza. Se utiliza $k = 3$ y distancia *euclidiana* como parámetros para operación del clasificador, valores derivados de los resultados obtenidos durante el estudio de factibilidad presentado en sección 4.4.

El *Componente de Inferencia* no cuenta con interfaz gráfica de usuario, ya que es invocado por otros componentes cuando estos necesitan conocer la etiqueta asociada a la actual orientación de la cabeza del conductor, lo cual es transparente al usuario de la aplicación.

5.2.5.4 Componente de Validación

Debido a limitaciones de la plataforma Google Glass, no fue posible verificar en tiempo real la precisión del clasificador k-NN. Ya que esta versión del sistema sí cuenta con la funcionalidad de realizar inferencias en tiempo real, y para llevar a cabo lo anterior, se desarrolló el Componente de Validación, cuya interfaz de usuario se observa en la Figura 5.10. Este componente se utiliza para realizar sesiones de validación, donde se invocará al *Componente de Inferencia* y se registrarán las etiquetas producidas por este último junto a otra indicada por el conductor (*ground truth*), con motivo de comparar el porcentaje de coincidencia entre ambas.



Figura 5.10. Interfaz de usuario del Componente de Validación: **a)** Coincidencia entre el PAV indicado por el sujeto y el PAV inferido, **b)** Discrepancia entre el PAV indicado por el sujeto y el PAV inferido.

Al terminar cada sesión, se habrá generado un *Conjunto de Datos de Validación* con la estructura indicada en la Tabla 5.1, la cual puede trasladarse a una matriz de confusión para estimar la precisión del *Componente de Inferencia*, en tiempo real y mientras se conduce.

Tabla 5.1. Variables registradas en un Conjunto de Datos de Validación

Timestamp	PAV observado	PAV inferido
1582758409775	0	0
1582758409783	0	0
1582758409817	0	0
1582758409823	0	0
1582758409828	0	1
1582758409887	0	1

En la tabla anterior, los primeros 4 registros son una coincidencia entre el PAV indicado por el conductor y el inferido (Figura 5.10a), mientras que los últimos 2

corresponden a una discrepancia (Figura 5.10b). Los datos de validación son extraídos directamente del dispositivo cuando se requiere acceder a ellos.

5.2.5.5 Componente de Recolección de Datos del Comportamiento al Conducir (RDCC)

Este componente fue diseñado para recolectar datos del comportamiento al conducir durante la sesión de manejo, los cuales provienen de dos fuentes:

1. El PAV que se infiere de la orientación de la cabeza del conductor
2. Datos asociados al contexto de la conducción.

El contexto de la conducción, para este estudio, se definió usando las siguientes variables:

- Velocidad de manejo, capturada por el componente a través del sensor GPS, expresada en m/s.
- Tipo de camino por el que circula el conductor, este se determina posteriormente, mediante los datos de ubicación capturados por el componente a través del sensor GPS. Los caminos se dividen en dos tipos: arteriales y residenciales, propiamente definidos en la jerarquía de caminos (*Chapter 3: Functional Classification - Flexibility - Publications - Environment - FHWA, n.d.*).
- Acciones llevadas a cabo por el conductor, las cuales son indicadas por un anotador, y se categorizan de la siguiente manera:
 - Conducción en línea recta
 - Vuelta a la izquierda o a la derecha
 - Cambio de carril a la izquierda o a la derecha
 - Vehículo detenido en semáforo
 - Vehículo estacionado
- Presencia o ausencia de pasajero en cabina, la cual es indicada por un anotador.

Estas dos últimas variables fueron incluidas para estudiar su relación con los comportamientos visuales, y serán llamadas también *eventos*.

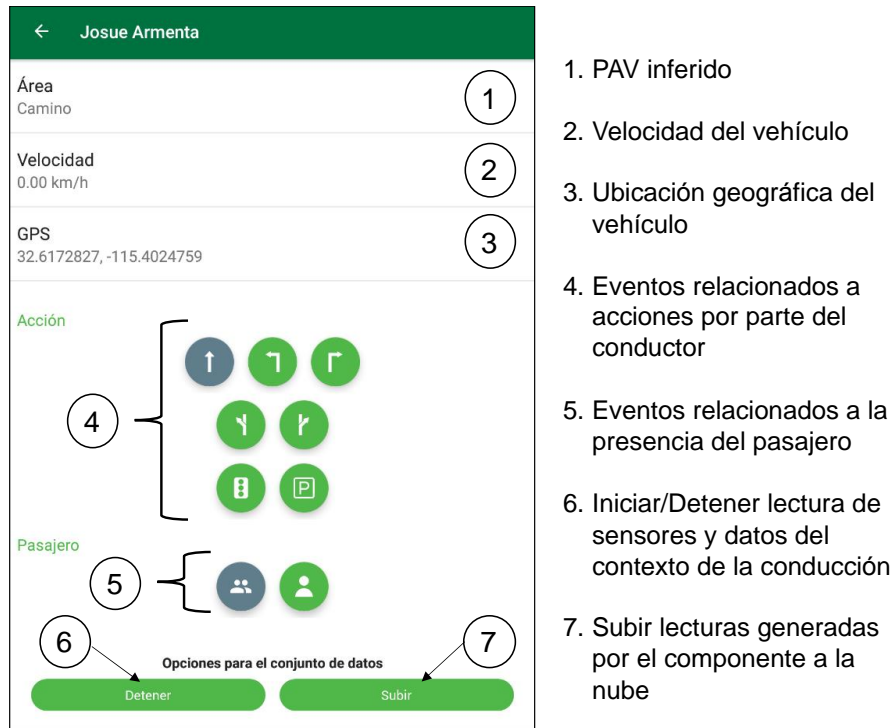


Figura 5.11. Interfaz de usuario del Componente de Recolección de Datos del Comportamiento al Conducir.

Se desarrolló una interfaz gráfica para facilitar la interacción con este componente, la cual se muestra en la Figura 5.11. Mediante esta interfaz, el anotador puede observar el PAV inferido en tiempo real, así como la velocidad y ubicación del vehículo en ese momento, indicados por los puntos 1 al 3. El punto 4 señala la acción llevada a cabo por el conductor, y el 5 la presencia o ausencia de pasajero en cabina, ambos eventos que deben ser actualizados por el anotador mediante la interfaz grafica, ya sea presionando el botón que corresponda a cada evento o a través de un *gamepad*. El botón señalado por el punto 6 le indica al componente cuando debe iniciar o detener la escritura de las variables anteriores en los datos de estudio, y el botón indicado por el punto 7 se utiliza para convertir dicho conjunto de datos en formato CSV y guardarlo en la instancia de Firebase Cloud Storage reservada para la aplicación.

La estructura del conjunto de datos de estudio producido por este componente se presenta en la Tabla 5.2

Tabla 5.2. Variables registradas en el Conjunto de Datos del Comportamiento al Conducir (DCC)

Timestamp	Clase	Latitud	Longitud	Velocidad	Acción	Pasajero
1582758409775	CAMINO	32.63069	-115.445	20	LINEA RECTA	PRESENTE

Una vez implementado el sistema de recolección de datos, se procedió a validar el modelo de inferencia para determinar su precisión en modo dinámico. Esta validación se presenta en la siguiente sección.

5.3 Validación del sistema

5.3.1 Prueba

Como se explicó durante el capítulo de Fundamentos teóricos, conseguir una alta precisión mediante el algoritmo de vecinos más cercanos no solo depende de los parámetros utilizados por este, sino que las instancias utilizadas durante el entrenamiento sean lo suficientemente diferentes entre sí cuando se trata de clases diferentes, pero lo más parecidas posibles dentro de una misma clase.

Para corroborar que los datos obtenidos a través de las lecturas combinadas de los componentes AHRS y ARF sean adecuadas como instancias de entrenamiento, se recolectaron conjuntos de datos de entrenamiento de cuatro sujetos (P1, P2, P3, P4) mediante el *Componente de Entrenamiento*. Posteriormente, utilizando la herramienta WEKA 3 (*Weka 3 - Data Mining with Open Source Machine Learning Software in Java*, n.d.), se probó cada conjunto de datos utilizando *10-fold cross-validation*.

Para el procedimiento de prueba, se obtuvo una precisión del 100% para los cuatro conjuntos de datos. Este resultado supera el obtenido con la primera versión del sistema (presentado en sección 4.4), lo cual se debe a que la inclusión de variables adicionales (Y_{RF} , Z_{RF}), capturadas mediante el componente ARF, permite describir mejor el movimiento de la cabeza en sus tres ejes. También indica que los parámetros utilizados para implementar el algoritmo k-NN ($k = 3$ y distancia euclidiana) son adecuados. A continuación, se presenta el procedimiento de validación y los resultados del desempeño del k-NN en tiempo real.

5.3.2 Validación

Si bien, en la etapa anterior se comprobó que las variables registradas en los conjuntos de datos de entrenamiento son suficientes para que el componente clasifique nuevas instancias con una buena precisión, en esta etapa se evalúa la inferencia durante la conducción.

Para llevar a cabo la validación, primero se generaron conjuntos de datos de entrenamiento de cuatro sujetos (P1, P2, P3, P4) mediante el *Componente de Entrenamiento*, todos ellos diferentes a los participantes del procedimiento de prueba, y después se utilizó el *Componente de Validación*, el cual a su vez invoca al *Componente de Inferencia*.

Para esta etapa, se solicitó a cada sujeto que manejara en condiciones no-naturalistas, durante 5 minutos, en un estacionamiento amplio, en horario sin afluencia de vehículos o personas, a un máximo de 20 km/h. Como se explicaba en la sección 5.4, el conductor es quien debe indicarle al componente cuando oriente su cabeza hacia un PAV, lo cual se establece como *ground truth*, y se compara contra el PAV inferido por el *Componente de Validación* en ese mismo momento. Para la indicación por parte del conductor se utilizó el *Dispositivo para envío de comandos*, pues sería peligroso pedirle al sujeto de prueba que dirigiera su atención hacia la tableta, mientras conduce, para interactuar con ella, sin contar que esto entorpecería el procedimiento de validación. Para reducir el error por intervención humana, se entrenó al conductor durante 5 minutos para que asociara cada etiqueta de PAV con su respectivo botón en el *gamepad*.

A lo largo del recorrido, un anotador le pedía al sujeto que observara de manera cíclica cada uno de los PAV diferentes al camino (Izquierda, Derecha, Piernas, Audio/Clima) y que, de manera simultánea, presionara el botón correspondiente a la etiqueta de dicho PAV. Por seguridad, cualquier PAV que no fuese el camino debía ser observado por un máximo de dos segundos; transcurrido ese lapso, el anotador le pedía al conductor que fijara su atención al camino e hiciera la indicación respectiva mediante el *gamepad*. Debido a que el conductor debía sujetar con una mano el volante y con otra el *gamepad*, el anotador le avisaba con anticipación al sujeto cual sería el siguiente PAV a observar, para que este acomodara su mano sobre el botón correspondiente.

Los resultados del proceso de validación para los cuatro participantes se observan en la Figura 5.12, de los que se obtienen las siguientes conclusiones:

- En ninguna de las validaciones se producen clasificaciones erróneas en las comparativas Izquierda – Derecha, Izquierda – Piernas e Izquierda – Audio/Clima y viceversa. Esto tiene sentido, pues el área izquierda es, a excepción del camino, el más alejado a todos los demás PAV dentro de cabina.
- En ninguna de las validaciones se producen clasificaciones erróneas en la comparativa Derecha – Piernas y viceversa. Esto tiene sentido, ya que para observar el área derecha de la cabina jamás se pasa por el área de las piernas.
- Derivado de lo anterior, las clasificaciones erróneas se dan entre áreas contiguas, lo cual tiene sentido cuando se considera que la métrica de similitud entre instancias se basa en distancias geométricas; el limite entre un área y otra pueden contener instancias con valores similares y dar lugar a confusiones en el clasificador.




Figura 5.12. Resultados del proceso de validación de la arquitectura. Los números en cada cuadro significan cantidad de instancias recolectadas para esa clase.

5.4 Interacción con el sistema para realizar el estudio

Para utilizar la nueva versión del sistema de sensado, es necesario recolectar datos con el *Componente de Recolección de Datos del Comportamiento al Conducir*. Para ello, el anotador debe seguir una secuencia definida de pasos, desde que recibe el dispositivo que contiene el componente ARMID, hasta la entrega del *Conjunto de Datos del Comportamiento al Conducir* en la nube. El escenario de uso del sistema para recolectar instancias es ilustrado en la Figura 5.13, y explicado a continuación:

El anotador debe iniciar el componente ARMID desde el dispositivo Google Nexus, donde se encuentra presente como una aplicación instalada. Desde este momento el anotador tiene la opción de interactuar con el componente mediante la interfaz táctil del dispositivo o utilizando el *Dispositivo de envío de comandos*. Una vez abierta la aplicación, se le presentará al anotador la interfaz gráfica del *Componente de Registro de Usuarios*, donde podrá seleccionar a un participante previamente registrado (5.13-1) o dar de alta a uno nuevo (5.13-2) para continuar hacia la siguiente pantalla.

Por defecto, se le presentará al anotador la interfaz gráfica del *Componente de Entrenamiento*, en el cual deberá llevar a cabo el procedimiento explicado en la sección 5.2.5.2 para generar los datos de entrenamiento del participante; en caso de que estos datos hayan sido capturados previamente, y requieran ser modificados, se utiliza el botón “Cargar” (5.13-3), el cual los traerá de vuelta del repositorio local *Conjunto de Datos de Entrenamiento*. Como se explicó en la sección antes mencionada, para introducir nuevas instancias a los datos de entrenamiento es necesario que el anotador seleccione un PAV de la lista (5.13-4) y presione el botón “Recolectar” (5.13-5) tanto para iniciar como para detener el registro de instancias. Una vez capturadas las instancias para todos los PAV de la lista, el anotador deberá presionar el botón “Guardar” (5.13-6) para almacenar los datos de entrenamiento en el repositorio local. Para extraer los datos de entrenamiento del usuario, se presiona el botón “Subir” (5.13-7), acción que enviará el conjunto hacia Firebase Cloud Storage. El botón “Limpiar” (5.13-8) removerá los datos previamente guardados del repositorio local. Almacenar los datos de entrenamiento le habilitará al anotador la opción

de acceder al *Componente de Recolección de Datos del Comportamiento al Conducir*, cuya interfaz gráfica es invocada mediante el botón “Estudio” (5.13-9).

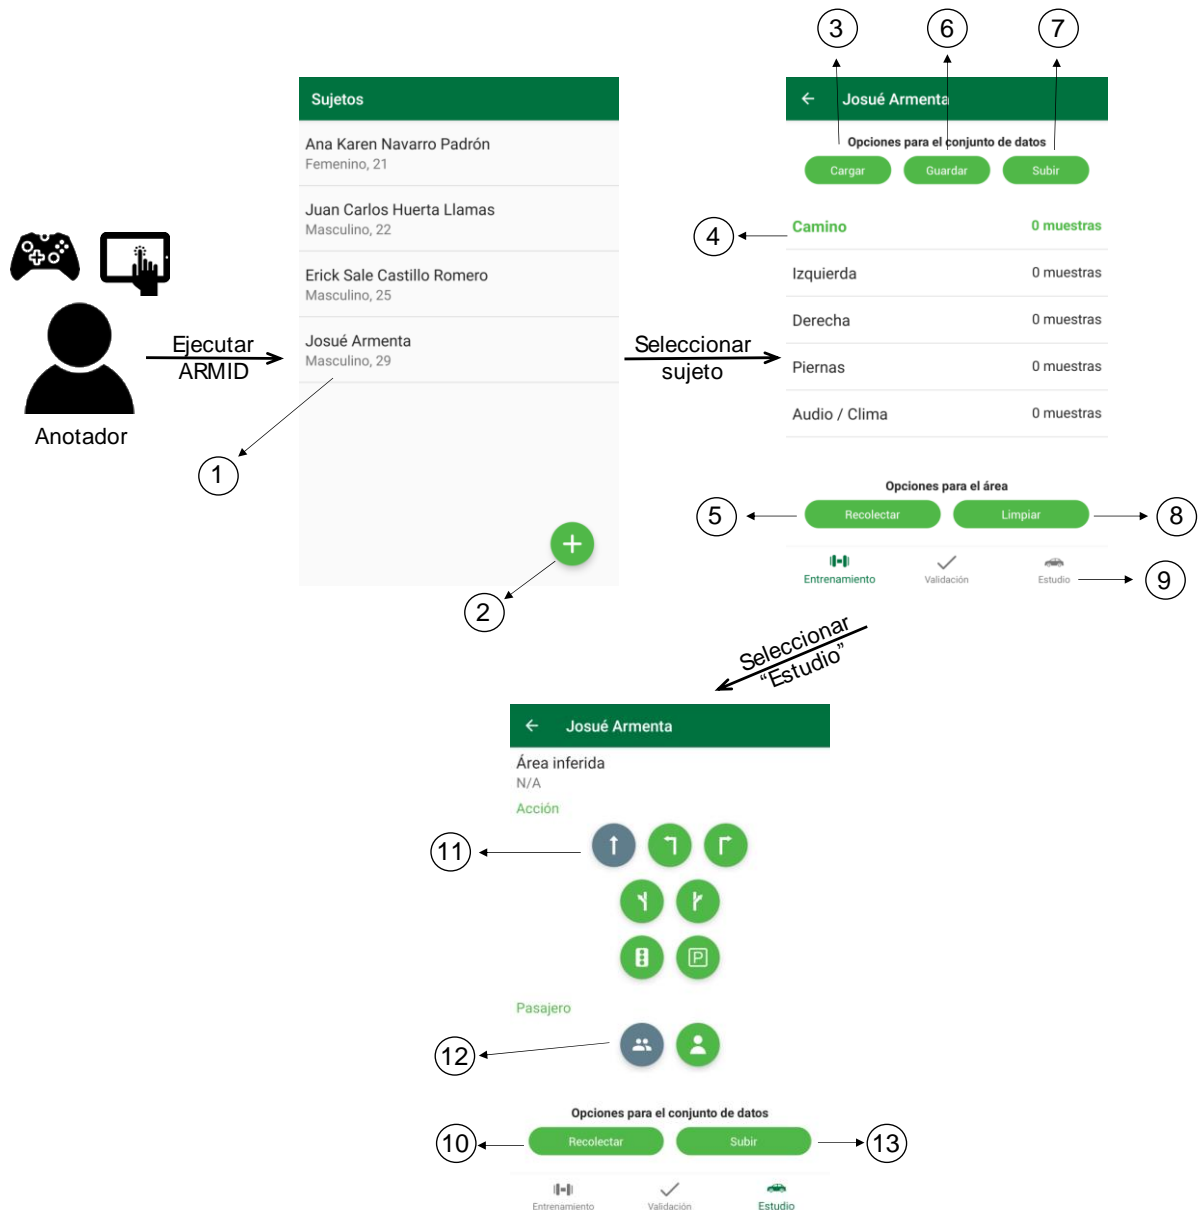


Figura 5.13. Escenario de uso para llevar a cabo la recolección de datos durante el estudio.

El procedimiento para recolectar las instancias de datos de comportamientos al conducir funciona en modo dinámico, es decir, con el automóvil en movimiento. Para comenzar con la recolección de datos, el anotador deberá presionar el botón “Recolectar” (5.13-10), lo cual iniciará la secuencia de eventos que se describe en la Figura 5.14. El anotador deberá, a su vez, indicarle al componente los eventos que ocurran durante la

conducción, puntualmente las acciones del conductor (5.13-11) y si hay o no presente un pasajero (5.13-12). Para terminar con la recolección de datos, el anotador deberá presionar el botón “Detener” (5.13-10). Finalmente, para extraer los datos adquiridos se presiona el botón “Subir” (5.13-13), lo cual enviará el conjunto recién adquirido hacia Firebase Cloud Storage.

Como se puede visualizar en la Figura 5.14, la generación de los datos del comportamiento al conducir es un proceso cíclico, con frecuencia de 50 Hz. Debido a la enorme dificultad que presenta para el anotador notificar al componente sobre la presencia de eventos con dicha frecuencia, estos últimos conservan su último valor y son registradas en la siguiente instancia como tal; esto quiere decir que, si, por ejemplo, se le notificó al componente que el conductor maneja en línea recta y no lleva un pasajero consigo, no será necesario modificarlas mediante la interfaz gráfica hasta que nuevos eventos ocurran.

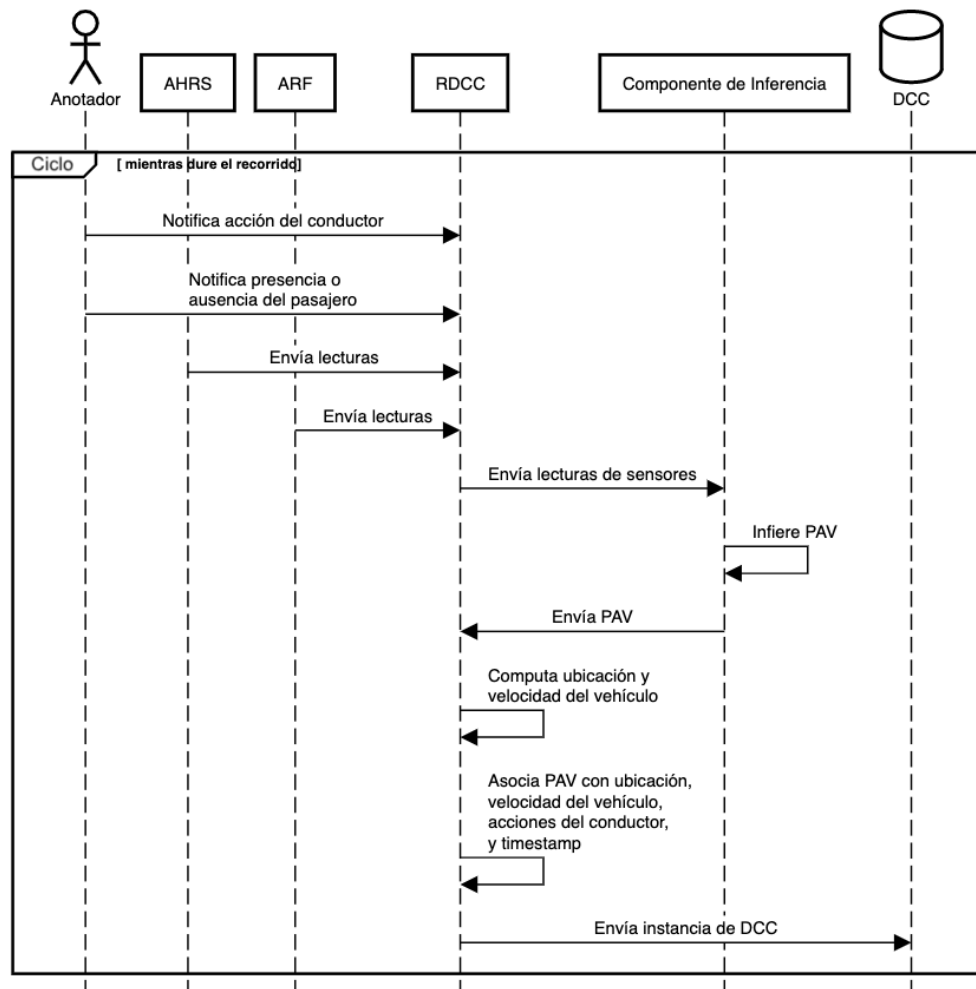


Figura 5.14. Diagrama de secuencia para generar el conjunto de datos de estudio.

Capítulo VI

Diseño del estudio de comportamientos durante la conducción

Si bien en el estudio de factibilidad quedó demostrada la efectividad de utilizar tecnologías basadas en el uso de sensores inerciales para recolectar datos durante la conducción, los cuales posteriormente fueron analizados para estudiar los comportamientos un grupo de adultos jóvenes, el objetivo de esta tesis requiere comparar los comportamientos al conducir entre dos grupos de edad, así como analizar su relación con variables asociadas a la aptitud para conducir, por lo que se diseñó un estudio que, empleando la versión del sistema descrito en el Capítulo 5, permitió abordar las Preguntas de Investigación planteadas en la Introducción y que se citan a continuación:

P1. ¿Cómo los comportamientos visuales se relacionan a variables del contexto de la conducción?

P2. ¿Cómo difieren los comportamientos visuales entre grupos de edad?

P3. ¿Cómo se relacionan los comportamientos visuales dentro de la cabina con una o más variables asociadas a la aptitud para conducir?

6.1. Participantes del estudio

6.1.1 Criterios de elegibilidad

Para ser elegibles, los participantes debían cumplir con los siguientes requisitos:

- Tener de 18 a 29 años de edad para pertenecer al grupo de adultos jóvenes.
- Tener 60 años o más de edad para pertenecer al grupo de los adultos mayores.
- Tener licencia de manejo vigente y automóvil propio con disponibilidad de usarlo para el estudio.
- No tener problemas de movilidad

- Resultado mínimo de 20/40 en la prueba de agudeza visual de Snellen, utilizando ambos ojos, el cual es requisito legal para conducir.

6.1.2 Técnicas de reclutamiento

Para el grupo de adultos jóvenes, se reclutaron estudiantes de la Universidad Autónoma de Baja California (U.A.B.C.), Campus Mexicali. Todos los estudiantes estaban inscritos en la asignatura de Inteligencia Artificial, en la cual utilizarían los datos recolectados para sus proyectos del curso. Por lo anterior, se comprometieron con el estudio, ya sea como voluntarios o contactando un participante externo que cumpliera con los criterios de elegibilidad.

Para el grupo de los adultos mayores, se colocaron volantes con información sobre el estudio en las instalaciones de la U.A.B.C., Campus Mexicali, y la versión digital de estos mismos fue publicada en redes sociales. También se reclutaron conocidos y familiares de los investigadores. A todos los participantes elegibles de este grupo se les proporcionó un incentivo económico de 150 MXN en gasolina.

6.2 Etapas del estudio

El estudio tuvo una duración aproximada de hora y media por participante, y consistió de las siguientes etapas:

- Aplicación de cuestionario demográfico y batería de pruebas cognitivas.
- Recolección de datos de entrenamiento.
- Recolección de datos de comportamiento.

Antes de comenzar con las recolecciones de datos de entrenamiento y comportamiento, se instalaron los dispositivos que contienen los componentes del sistema como se ilustra en la Figura 6.1:




Figura 6.1. Ubicación de los dispositivos dentro de cabina.

Debido a que esta configuración se utiliza para ambas recolecciones, se llevaron a cabo de manera sucesiva. A continuación, se describe a detalle cada una de las etapas del estudio.


6.2.1 Aplicación de cuestionario demográfico y batería de pruebas cognitivas

Al inicio de la sesión, se aplicó un cuestionario demográfico a cada participante, donde se recabó su nombre completo, género, edad, y experiencia de manejo (años cumplidos como conductor).

Con motivo de contrastar las habilidades cognitivas entre ambos grupos de edad, se aplicó una batería de pruebas cognitivas en todos los participantes, la cual consiste de las pruebas Mini-Mental State Examination, Trail Making Test A, Trail Making Test B, Digit Symbol Substitution, Digit Span Forward, y Digit Span Backward. Las pruebas de esta batería son instrumentos validados que tienen la finalidad de valorar la capacidad cognitiva de los sujetos en varios dominios que están asociados a la aptitud para conducir (*fitness-to-drive*) (Brouwer et al., 1991)(Karlene K Ball, 1997)(De Raedt & Ponjaert-Kristoffersen, 2001)(Freund et al., 2002)(Wikman & Summala, 2005).

La aplicación de la batería de pruebas cognitivas tiene una duración aproximada de media hora por participante. El objetivo de cada prueba se explica a continuación.

La prueba Mini-Mental State Examination (MMSE) se utiliza para valorar si el sujeto posee algún grado de deterioro cognitivo, relacionado a la demencia senil (Pangman et al., 2000). Consiste en varias preguntas asociadas a cada uno de los cinco dominios cognitivos que evalúan. Por ejemplo, para evaluar la orientación espacio-temporal se pregunta “¿dónde te encuentras? ¿qué día de la semana es hoy?”, para evaluar la capacidad de seguir instrucciones se le solicita al sujeto que realice acciones como escribir en una hoja, levantar una pluma. Se evalúa la capacidad cognitiva, otorgando un punto por cada pregunta bien contestada o instrucción correctamente ejecutada, según corresponda. El máximo puntaje obtenido es de 30 puntos. Para diagnosticar el grado de deterioro cognitivo se utilizan los rangos de puntaje que se muestran en la Figura 6.2b.



(a)

Puntaje	Diagnóstico del estado mental
27- 30	Funcionamiento normal
24-26	El sujeto requiere una revisión preventiva
20-23	Indicios ligeros de demencia
13-19	Indicios moderados de demencia
1 - 12	Demencia

(b)

Figura 6.2. MMSE: **a)** Ejemplo de ejercicio en la prueba, donde la figura debe ser replicada por el participante, **b)** Puntajes para evaluar el estado mental.

La prueba Trail Making Test A (TMT-A) mide la velocidad de procesamiento, definida como el tiempo que le toma a una persona ejecutar una tarea mental (Reitan, 1958). Su resultado está altamente correlacionado al desempeño para conducir (Hopewell, 2002). Durante la prueba se le pide al sujeto que conecte una serie de círculos numerados del 1 al 25, distribuidos en una hoja de papel (Figura 6.3a) El sujeto debe conectar los puntos de manera ascendente, lo más rápido y correctamente que le sea posible. El puntaje es la cantidad en segundos que le toma al sujeto terminar con la tarea: cuanto más alto sea este, mayor deterioro en su velocidad de procesamiento. En caso de equivocarse no se

detiene la prueba y simplemente se le indica al sujeto que tiene un error y debe corregirlo. Los resultados de la valoración son mostrados en la Figura 6.3b.

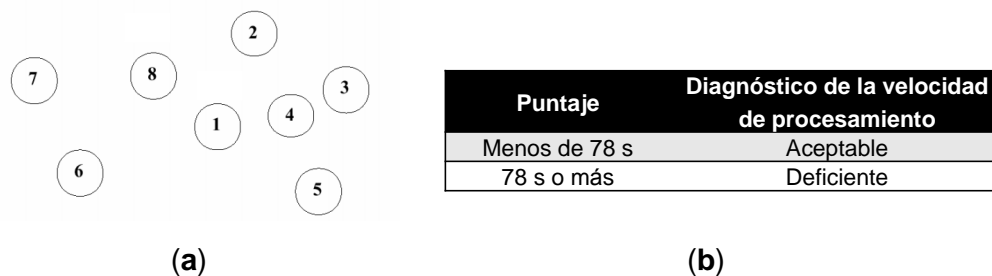


Figura 6.3. TMT-A: **a)** Ejemplo de elementos a unir, **b)** Puntajes para evaluar la velocidad de procesamiento.

La prueba Trail Making Test B (TMT-B) mide la flexibilidad mental, definida como la capacidad del cerebro para adaptar la conducta y pensamiento a situaciones cambiantes (Reitan, 1958). El resultado de esta prueba también está altamente correlacionado al desempeño para conducir (Hopewell, 2002). Durante la prueba se le pide al sujeto que conecte una serie de círculos, unos contienen números (1-13) y otros con letras (A-L), distribuidos en una hoja de papel tal como se muestra en la Figura 6.4a. El sujeto debe conectar los círculos de manera ascendente e intercalada entre números y letras, esto es 1-A-2-B-3-C, etc. El puntaje es la cantidad en segundos que le toma al sujeto terminar con la tarea: cuanto más alto sea este, mayor deterioro en su flexibilidad mental. En caso de equivocarse, no se detiene la prueba y simplemente se le indica al sujeto que tiene un error y debe corregirlo. Los resultados de la valoración son mostrados en la Figura 6.4b.




Figura 6.4. TMT-B: **a)** Ejemplo de elementos a unir, **b)** Puntajes para evaluar la flexibilidad mental.

La prueba Digit Symbol Substitution (DSST) mide la atención (Jaeger, 2018). Se le entrega al sujeto una hoja con una serie de números (1-9) a los cuales le corresponde un símbolo diferente a cada uno. Bajo un renglón con números, el sujeto deberá copiar el símbolo correspondiente a cada dígito (Figura 6.5a), con un tiempo límite de 90 segundos. El puntaje es la cantidad de símbolos copiados correctamente durante este periodo de tiempo, con una máxima calificación de 90. Los resultados de la valoración son mostrados en la Figura 6.5b.

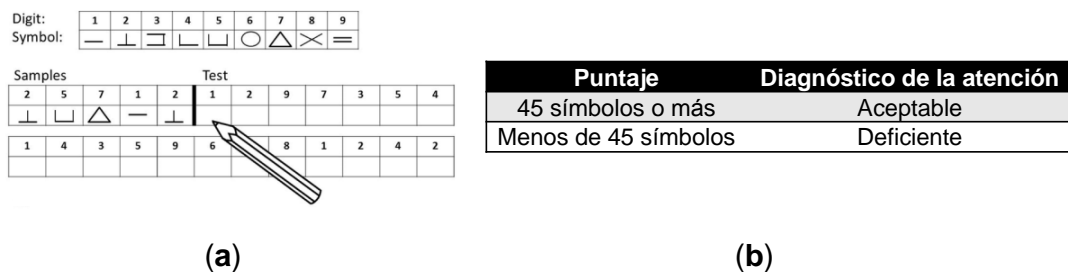


Figura 6.5. DSST: **a)** Ejemplo de símbolos a sustituir, **b)** Puntajes para evaluar la atención.

Las pruebas Digit Span Forward (DS-F) y Digit Span Backward (DS-B) miden la memoria de trabajo, la cual se define como la capacidad para contener temporalmente información a procesar, y está asociada al razonamiento y capacidad de tomar decisiones (Diamond, 2013). En DS-F, se le presentan de manera oral al sujeto una serie de números en el rango del 1 al 9, comenzando con una serie de tres dígitos y anunciados a razón de uno por segundo, los cuales deberá escuchar, recordar y repetir. Independientemente si los dígitos son pronunciados correcta o incorrectamente, se le vuelve a presentar otra serie de tres dígitos al sujeto, donde deberá volver a escuchar, recordar y repetirlos. Si el sujeto es capaz de pronunciarlos correctamente en una de las dos secuencias, se le presentan ahora una serie de cuatro dígitos, y así sucesivamente. La calificación será igual a la cantidad de dígitos en la última secuencia que pudo recordar y pronunciar de manera correcta en cualquier de los dos intentos disponibles. La prueba termina con dos fallas continuas en una misma serie. DS-B es muy parecida a la prueba anterior, pero difiere en que el sujeto deberá enunciar la serie de manera inversa a como se le fue presentada. La calificación final es la suma de los resultados de ambas pruebas, y se recomienda que sean aplicadas de

manera consecutiva, comenzando con DS-F. Los resultados de la valoración son mostrados en la Figura 6.6b.

Forward	Backward	Diagnóstico de la memoria de trabajo	
Sequences		Puntaje	
5, 8, 2	6, 2, 9	10 puntos o más	Aceptable
6, 9, 4	4, 1, 5	Menos de 10 puntos	Deficiente
6, 4, 3, 9	3, 2, 7, 9		
7, 2, 8, 6	1, 9, 6, 8		
4, 2, 7, 3, 1	1, 5, 2, 8, 6		
7, 5, 8, 3, 6	6, 1, 8, 4, 3		

(a)

(b)

Figura 6.6. DS-F y DS-B: **a)** Ejemplo de secuencias a repetir al derecho y al revés, **b)** Puntajes para evaluar la memoria de trabajo.

6.2.2 Recolección de datos de entrenamiento

El propósito de esta etapa del estudio es generar un conjunto de datos de entrenamiento para cada sujeto, y se lleva a cabo utilizando el *Componente de Entrenamiento*, cuya operación se detalló en la sección 5.2.5.2. Esta etapa tiene una duración de aproximadamente 10 minutos y debe llevarse a cabo antes de la recolección de datos de comportamiento.

6.2.3 Recolección de datos de comportamiento

Esta etapa consiste en una sesión de manejo, a través de una ruta previamente establecida, con una duración de aproximadamente 45 minutos, y se lleva a cabo utilizando el *Componente de Recolección de Datos del Comportamiento al Conducir*, cuya operación se detalló en la sección 5.2.5.5. Su propósito es generar un conjunto de datos de comportamiento.

La cantidad de registros en los datos de comportamiento puede variar de manera significativa entre sujetos por que, aunque se recorre la misma ruta, diferencias en la cantidad de tráfico, velocidad y estilo de conducción de cada participante afectan el número de instancias registradas.

6.3 Características de la ruta de manejo

Al igual que en el estudio de factibilidad, se decidió incluir dos tipos de camino en la ruta a recorrer por todos los participantes durante la recolección de datos de comportamiento: caminos arteriales y residenciales. El recorrido tiene una longitud de 17.5 km y posee las siguientes características:

- 12 km de caminos arteriales
- 5.5 km de caminos residenciales
- 25 semáforos presentes
- 20 altos
- 6 vueltas a la derecha
- 12 vueltas a la izquierda

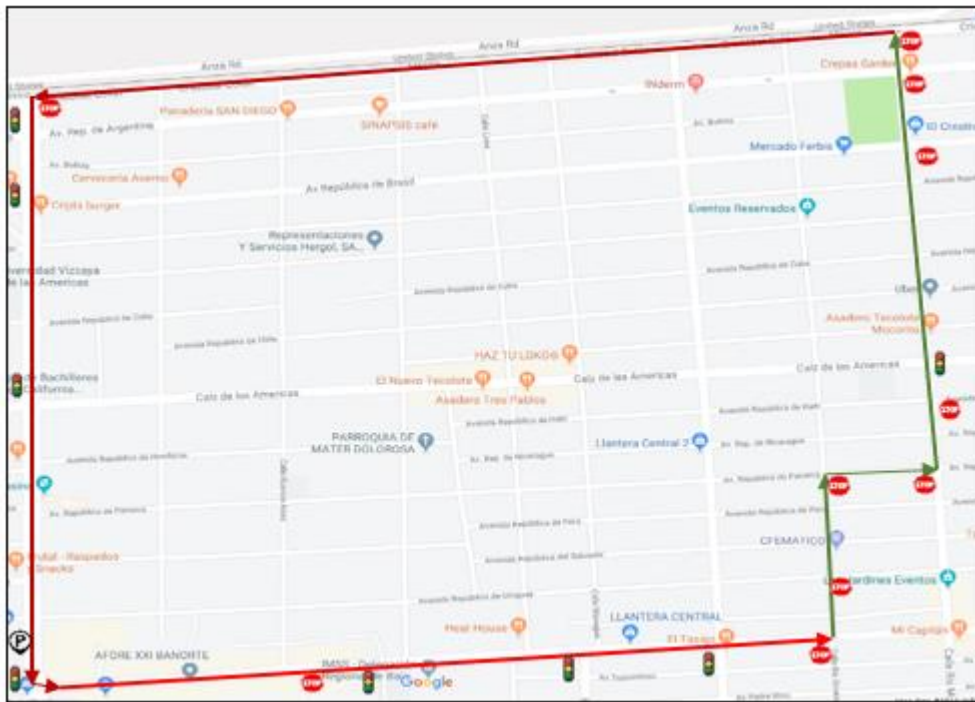
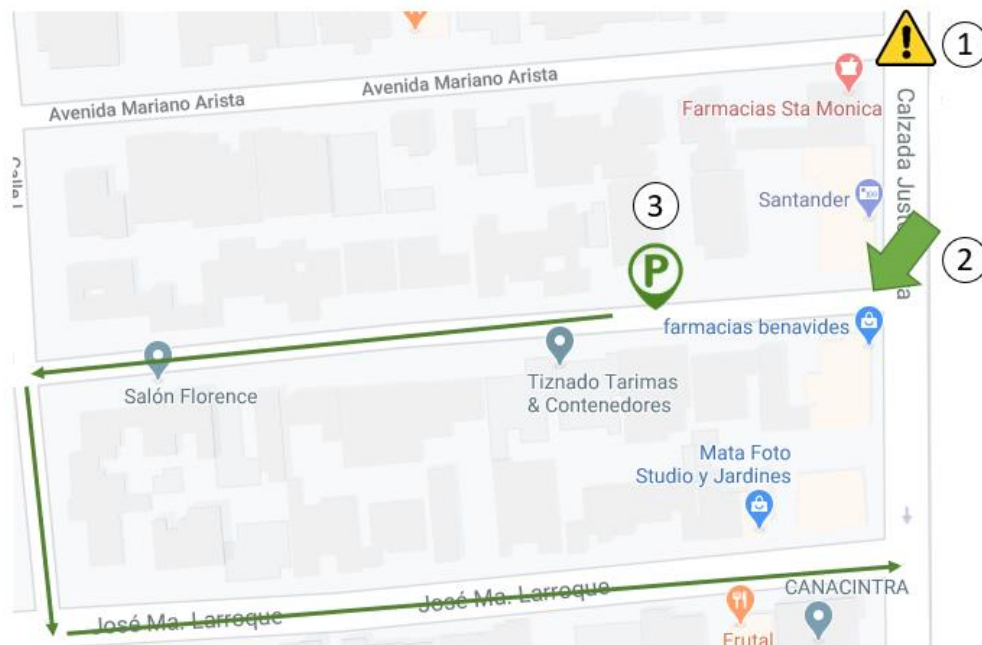


Figura 6.7. Fragmento de la ruta de manejo. Las flechas rojas señalan el flujo del tráfico en caminos arteriales; las flechas verdes señalan el flujo del tráfico en caminos residenciales.

6.4 Indicaciones en la sesión de manejo

El objetivo de solicitarle a cada participante el uso de su propio vehículo fue para asegurar un comportamiento natural de este durante la sesión de manejo, lo cual incluye libre interacción con los PAV en cabina, velocidad de manejo y conducción por el carril de su preferencia, al contar todas las calles recorridas con al menos dos de ellos.

Sin embargo, para estudiar ciertos comportamientos visuales fue necesario asegurar la ejecución de dos eventos a la mitad del recorrido: la acción de estacionarse y “remove” la presencia del pasajero, procedimiento ilustrado en la Figura 6.8.



1. Aviso al conductor de dar vuelta a la izquierda
2. Selección de etiqueta “Estacionarse” por parte del anotador
3. Selección de etiquetas “Sin pasajero” y “Conducir en línea recta” por parte del anotador

Figura 6.8. Procedimiento para llevar a cabo la acción de estacionarse e indicar la ausencia de pasajero en cabina.

La presencia o ausencia del pasajero se refiere al tipo de interacciones que el participante tiene con él y no a su presencia o ausencia física en la cabina. De esta manera, durante la primera mitad del recorrido (6 km de caminos arteriales y 2.75 de caminos residenciales) el sujeto de prueba tiene la libertad de interactuar libremente con su pasajero,

ya sea recibiendo instrucciones de su parte (por donde dirigirse, por ejemplo) o entablando conversación. Durante la segunda mitad, cuando el pasajero ha sido “removido”, las interacciones se limitan a solo recibir instrucciones. El objetivo de hacer esto fue conocer como variaban los comportamientos al conducir cuando se tiene y no se tiene un pasajero presente en el vehículo.

6.5 Preparación y procesamiento de datos recolectados

6.5.1 Preparación de datos

Con el propósito de facilitar el análisis de los comportamientos al conducir, se desarrollaron dos aplicaciones en MATLAB R2018b. La primera de estas opera directamente sobre el *Conjunto de Datos del Comportamiento al Conducir*.

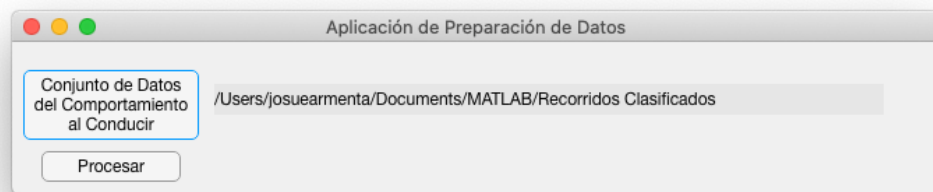


Figura 6.9. Aplicación de preparación de datos.

El proceso de preparación para dicho conjunto de datos consta de dos partes:

1. Corrección de datos: Debido a que el componente de clasificación no posee una precisión del 100%, para realizar una mejor estimación de la duración de la mirada hacia los PAV es necesario corregir inferencias consideradas como incorrectas. Dentro del conjunto de datos, se consideran como *un vistazo* el conjunto de entradas cuyo valor de clase contenga el mismo PAV de manera consecutiva e ininterrumpida, y su *duración* la diferencia del valor *timestamp* entre la última y primera entrada de dicha agrupación. Si esta duración es menor a 100 milisegundos, no se le considera un vistazo válido (Bärgman et al., 2015), y, por consiguiente, la clase para dicha agrupación es cambiada a la del grupo anterior válido.

2. Transformación de datos: Cada entrada de la columna *velocidad* es multiplicada por 3.6 para convertirla de m/s a km/h, la unidad en la que se expresa la velocidad de los vehículos. Las variables *latitud* y *longitud*, al expresar en conjunto una ubicación, se convierten en el nombre de *la calle* y el *tipo de camino* donde se encontraba el vehículo cuando sus valores fueron registrados. Esto, al igual que la velocidad, para facilitar su manipulación durante la etapa de análisis de datos.

Datos de estudio

TIMESTAMP	CLASE	VELOCIDAD (M/S)	LATITUD	LONGITUD	ACCIÓN	PASAJERO
1570811749212	IZQUIERDA	9.38	32.66746	-115.436	LINEA RECTA	PRESENTE
1570811749246	IZQUIERDA	9.38	32.66746	-115.436	LINEA RECTA	PRESENTE
1570811749254	CAMINO	9.38	32.66746	-115.436	LINEA RECTA	PRESENTE
...
1570811749588	IZQUIERDA	9.38	32.66746	-115.436	LINEA RECTA	PRESENTE
1570811749616	IZQUIERDA	9.38	32.66746	-115.436	LINEA RECTA	PRESENTE
1570811749648	IZQUIERDA	9.38	32.66746	-115.436	LINEA RECTA	PRESENTE



Datos preparados de estudio

TIMESTAMP	CLASE	VELOCIDAD (KM/H)	CALLE	TIPO CAMINO	ACCIÓN	PASAJERO
1570811749212	IZQUIERDA	33.75	AVE RIO MOCORITO	RESIDENCIAL	LINEA RECTA	PRESENTE
1570811749246	IZQUIERDA	33.75	AVE RIO MOCORITO	RESIDENCIAL	LINEA RECTA	PRESENTE
1570811749254	IZQUIERDA	33.75	AVE RIO MOCORITO	RESIDENCIAL	LINEA RECTA	PRESENTE
...
1570811749588	IZQUIERDA	33.75	AVE RIO MOCORITO	RESIDENCIAL	LINEA RECTA	PRESENTE
1570811749616	IZQUIERDA	33.75	AVE RIO MOCORITO	RESIDENCIAL	LINEA RECTA	PRESENTE
1570811749648	IZQUIERDA	33.75	AVE RIO MOCORITO	RESIDENCIAL	LINEA RECTA	PRESENTE

Figura 6.10. Comparativa de la estructura de la tabla para un conjunto de datos antes y después de ser preparado mediante la aplicación de preparación de datos.

Al conjunto de datos que resulta del proceso anterior se le conoce como *datos preparados (de estudio)*, tiene formato CSV y funciona como entrada para la siguiente aplicación. La comparativa entre los datos de entrada y salida en este procesamiento se ilustra en la Figura 6.10. Para facilitar el procedimiento, basta con indicar en la interfaz gráfica (Figura 6.9) la ubicación del directorio que contiene los datos de comportamiento de todos los sujetos y estos serán preparados mediante una operación por lotes, evitando así el tratamiento de cada uno por separado.

6.5.2 Partición de datos

La segunda aplicación, también desarrollada mediante MATLAB, toma como entrada los conjuntos de datos preparados y, mediante una interfaz gráfica (Figura 6.11), permite filtrar o limitar las condiciones bajo las cuales se desea estudiar los comportamientos visuales del conductor.

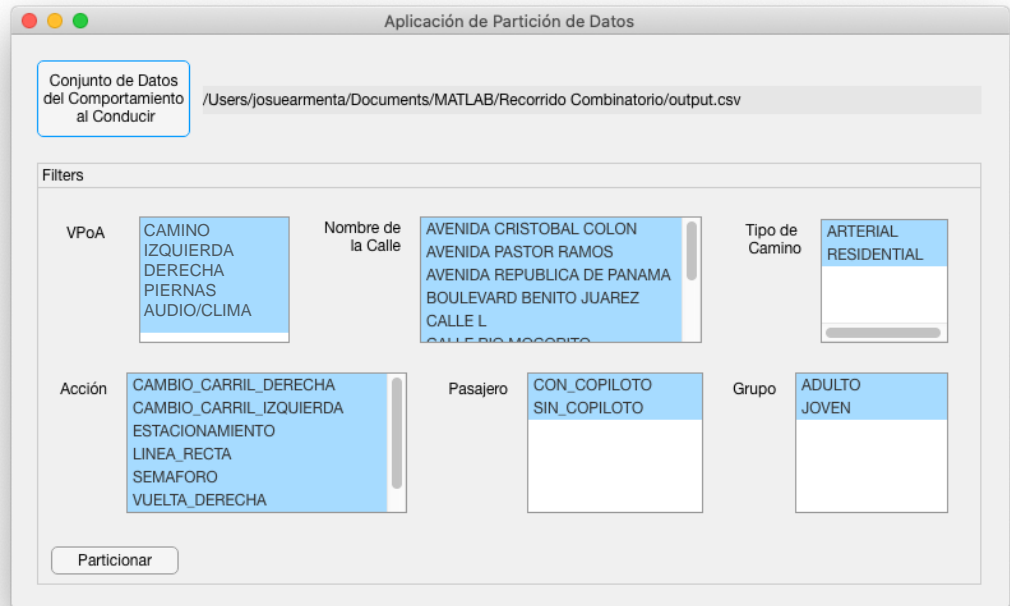


Figura 6.11. Aplicación de partición de datos.

A cada conjunto de datos preparado le es asignado un ID, reservando los identificadores P1-P15 para los adultos jóvenes y P16-P30 para los adultos mayores. De esta manera, mediante la aplicación de *partición de datos* es posible filtrar los comportamientos visuales por grupo(s) de edad y participante(s) (Figura 6.11).

El objetivo de esta herramienta es establecer las condiciones bajo las cuales se quiere obtener las variables *cantidad de vistazos* y *duración de la mirada* (Figura 6.12). Pese a que cualquier aplicación que maneje archivos CSV podría filtrar las entradas por los valores en sus columnas, esta aplicación se encarga de aplicar esta operación en *todos* los conjuntos de datos al mismo tiempo, además de reducir los conjuntos a las variables

mencionadas anteriormente. De esta manera es posible analizar, por ejemplo, si existe diferencia significativa en la cantidad de vistazos al área del camino entre los dos grupos de edad cuando estos conducían a 60 km/h en caminos de tipo arterial con el pasajero presente.

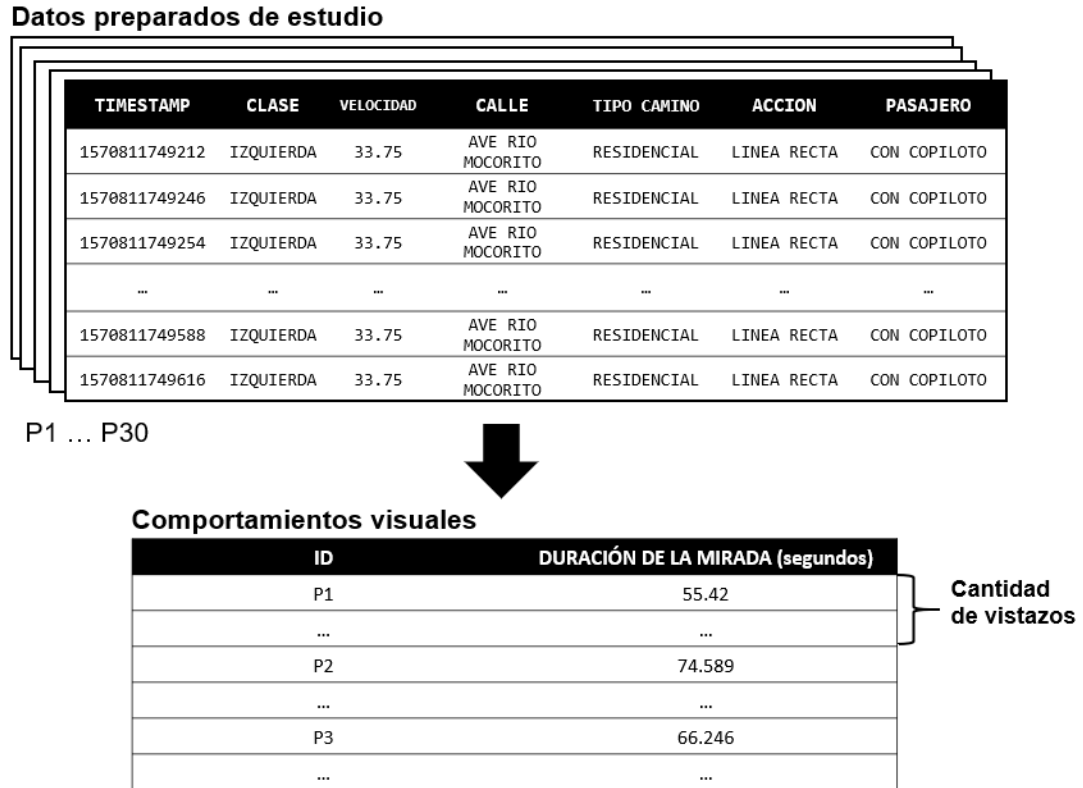


Figura 6.12. Los conjuntos de datos preparados (de estudio) son reducidos a una lista de vistazos por participante, con su respectiva duración en segundos.

6.6 Análisis estadístico de datos

Para el análisis de los datos se utilizaron herramientas de estadística descriptiva y calculadoras estadísticas del sitio Social Science Statistics (*Social Science Statistics*, n.d.), las cuales son:

- Normalidad de los datos: *Prueba de Kolmogorov-Smirnov*. Ya que se utilizaron pruebas estadísticas que requieren datos normalizados (mencionadas abajo), esta prueba se uso de manera previa. Aquellos conjuntos de datos que resultasen no-normalizados fueron convertidos a la escala [0,1] para su uso.

- Comparativa de medias en un mismo grupo, usando diferentes condiciones: *Prueba de los rangos con signo de Wilcoxon*, $p = .05$, bilateral (dos colas). Es decir, con esta técnica estadística se buscaron diferencias del mismo grupo utilizando diferentes condiciones del contexto de la conducción. Por ejemplo, con esta técnica se valoró si el grupo de jóvenes, la cantidad de vistazos a la zona de piernas (asociada a bajar la cabeza para ver el teléfono) es significativamente diferente en la condición “semáforo en rojo” que en “conducción”. Similarmente se valoraron estas condiciones para el grupo de adultos mayores.
- Comparativa de medias independientes entre grupos: *Prueba t de Student*, $p = .05$, bilateral (dos colas). Esta técnica se utilizó para comprender las diferencias en comportamientos visuales entre grupos de edad. Por ejemplo, se valoró si la cantidad de vistazos a la zona de piernas entre el grupo de jóvenes y de adultos mayores es significativamente diferente.
- Detección de valores atípicos: *Método de Tukey*, $k = 1.5$. Teniendo un conjunto de observaciones, es utilizado para identificar los datos cuyos valores sean atípicos, es decir, difieran de manera significativa a los demás. Por ejemplo, al analizar la experiencia de manejo de un grupo de conductores, este método determina cuales de estos han conducido por más o menos años de lo que se consideraría *normal* en la agrupación (valores que se encuentran, aproximadamente, en el rango abarcado por los cuartiles inferior y superior del conjunto de datos).
- Correlaciones: *Coefficiente de correlación de Pearson*, $p = .05$; los resultados de las correlaciones fueron interpretados de acuerdo a los siguientes criterios (Akoglu, 2018):
 - $0 < |r| < 0.3$ es una correlación débil
 - $0.3 < |r| < 0.7$ es una correlación moderada
 - $|r| > 0.7$ es una correlación fuerte.

La correlación se utilizó para identificar asociaciones entre variables del contexto de la conducción con los comportamientos visuales, por ejemplo, entre velocidad y cantidad de vistazos a PAV. Adicionalmente, se utilizó para comprender las asociaciones que existente entre las variables asociadas a la aptitud para conducir y los comportamientos visuales a PAV.

Capítulo VII

Resultados

7.1 Características demográficas

Treinta participantes fueron reclutados, basados en los criterios de elegibilidad y técnicas de reclutamiento (ver sección 6.1), contando los grupos de edad de adultos jóvenes y adultos mayores con 15 participantes cada uno. No hubo un balance de género de los participantes dentro de cada grupo. Este desbalance, en cuanto al grupo de jóvenes, se debió a que fueron reclutados de un grupo de Ingeniería en el que la mayoría eran estudiantes hombres; mientras que, en el grupo de adultos mayores, hubo más mujeres que se ofrecieron como voluntarios. Ya que no se analizaron los datos considerando como variable independiente el género, esta característica demográfica no afecta los resultados del estudio.

El grupo de los adultos jóvenes consintió en 10 hombres y 5 mujeres, con edades entre los 21 y 27 años ($M = 22.93$, $SD = 2.34$) y experiencia de manejo entre 2 y 10 años ($M = 5.2$, $SD = 2.04$). El grupo de los adultos mayores estuvo integrado por 5 hombres y 10 mujeres, con edades entre los 60 y 73 años ($M = 65.53$, $SD = 3.93$) y experiencia de manejo entre 40 y 55 años ($M = 46.33$, $SD = 4.59$). Utilizando el *método de Tukey* de forma independiente para cada grupo, no se presentaron valores atípicos (*outliers*) en los años de experiencia como conductor; esto quiere decir que ningún participante difería de manera significativa con su experiencia de manejo a comparación de los demás sujetos en el mismo grupo de edad. Algunas de las características demográficas de los participantes son mostradas en la Tabla 7.1.

Tabla 7.1. Características demográficas de los participantes

Variable	Adultos jóvenes	Adultos mayores
Sexo		
Hombre	10	5
Mujer	5	10
Edad (años)		
<i>M</i>	22.93	65.53
<i>SD</i>	2.34	3.93
Rango	21 – 27	60 – 73
Experiencia de manejo (años)		
<i>M</i>	5.2	46.33
<i>SD</i>	2.04	4.59
Rango	2 – 10	40 – 55

7.2 Datos recolectados

En la Tabla 7.2 se presenta la duración y velocidad de cada uno de los participantes para el recorrido del estudio. El grupo de los adultos jóvenes realizó dicho recorrido con una media de 22.45 km/h, con un tiempo promedio de 43.21 minutos, mientras que el grupo de los adultos mayores recorrió la misma trayectoria con una velocidad media de 24.86 km/h, en un tiempo promedio de 36.26 minutos. Las desviaciones estándar intragrupo sugieren que los participantes conducen a una velocidad homogénea. Aunque ambos grupos manejaron a una velocidad media parecida, la duración promedio del recorrido varió por aproximadamente 7 minutos, lo cual quiere decir que, bajo una misma tasa de muestreo, la cantidad total de instancias recolectadas para cada grupo de edad se verá afectada por dicha diferencia en el tiempo promedio del recorrido. Estas cantidades son mostradas en las Tablas 7.3 y 7.4.

Aunque el grupo de adultos jóvenes recolectó una mayor cantidad de instancias ($M = 101,645$, $SD = 14,540$) a comparación del grupo de adultos mayores ($M = 84,658$, $SD = 8,101$), aplicando la prueba estadística *t de Student* no se encontró una diferencia significativa en el número de instancias capturadas entre ambos grupos, $t(28) = 0.45292$, $p = .652297$. La diferencia en el tiempo promedio que le tomó a cada grupo realizar el recorrido se explica por la cantidad de tráfico: mientras que las recolecciones del grupo de

adultos jóvenes se realizaron dentro de periodo escolar, las de los adultos mayores fueron llevadas a cabo en periodo vacacional, donde hay una menor afluencia de vehículos. Si bien las diferencias en condiciones del tráfico pudieran afectar los comportamientos visuales en cada sujeto (e.g. la cantidad de semáforos en rojo, o embotellamientos), se trata de factores muy difíciles de controlar, por lo que se decidió desestimar su impacto para efectos de este estudio.

Tabla 7.2. Duración y velocidad durante el recorrido de todos los participantes

Adultos Jóvenes			Adultos Mayores		
ID	Duración del recorrido ¹	Velocidad ² M (SD)	ID	Duración ¹	Velocidad ² M (SD)
P1	48.38	21.53 (18.58)	P16	36.31	24.66 (20.75)
P2	40.91	25.74 (21.84)	P17	34.58	26.09 (18.15)
P3	57.01	18.48 (19.58)	P18	34.57	26.15 (17.70)
P4	39.25	26.80 (21.34)	P19	33.96	26.59 (18.51)
P5	35.75	29.72 (22.79)	P20	31.93	28.18 (19.01)
P6	34.68	30.47 (22.71)	P21	37.78	23.76 (18.72)
P7	35.88	29.44 (22.00)	P22	35.20	25.50 (18.75)
P8	42.61	24.16 (21.04)	P23	34.74	26.04 (19.25)
P9	44.96	23.64 (20.58)	P24	42.60	21.41 (16.35)
P10	50.48	21.59 (20.29)	P25	40.56	22.17 (17.72)
P11	42.72	24.61 (21.64)	P26	43.32	20.86 (17.52)
P12	44.61	23.68 (22.28)	P27	35.48	25.40 (18.68)
P13	42.57	24.27 (19.73)	P28	33.77	26.59 (17.10)
P14	40.98	27.17 (20.64)	P29	34.20	26.48 (18.49)
P15	47.36	22.15 (20.08)	P30	34.87	25.83 (19.50)
M	43.21	24.45	M	36.26	24.86
SD	5.99	3.37	SD	3.35	2.1

¹duración del recorrido expresada en minutos, ²velocidad expresada en km/h

En la Tabla 7.3 se observa que el PAV que más atención recibe por parte de los adultos jóvenes es el camino o parabrisas (85.5%), seguido del área izquierda de la cabina (8.77%) y después el área de las piernas (3.2%). De los PAV restantes, el área del audio/clima (1.80%) recibió más tiempo de atención que el área de la derecha (1%, o una de 100 instancias).

Tabla 7.3. Cantidad de datos recolectados por participante del grupo de adultos jóvenes, donde cada unidad es un PAV detectado por cuadro de video

ID	Camino	%	Izquierda	%	Derecha	%	Piernas	%	Audio/ Clima	%	Total
P1	102,131	90.65	7,517	6.67	1,824	1.62	376	0.33	818	0.73	112,666
P2	83,733	86.37	7,287	7.52	1,842	1.90	1,809	1.87	2,272	2.34	96,943
P3	104,603	77.57	16,512	12.24	718	0.53	7,889	5.85	5,130	3.80	134,852
P4	65,357	70.08	15,720	16.86	2,856	3.06	4,305	4.62	5,023	5.39	93,261
P5	78,009	93.69	1,610	1.93	674	0.81	1,451	1.74	1,518	1.82	83,262
P6	76,400	92.83	1,809	2.20	886	1.08	2,141	2.60	1,064	1.29	82,300
P7	61,100	71.82	15,331	18.02	625	0.73	5,195	6.11	2,819	3.31	85,070
P8	90,147	91.11	7,080	7.16	42	0.04	1,260	1.27	414	0.42	98,943
P9	92,395	86.50	8,421	7.88	823	0.77	3,973	3.72	1,199	1.12	106,811
P10	96,888	80.92	16,124	13.47	683	0.57	3,413	2.85	2,625	2.19	119,733
P11	94,073	92.70	4,687	4.62	629	0.62	162	0.16	1,931	1.90	101,482
P12	87,886	82.83	10,229	9.64	2,324	2.19	4,793	4.52	875	0.82	106,107
P13	88,657	87.73	11,065	10.95	905	0.90	238	0.24	189	0.19	101,054
P14	74,210	82.86	3,244	3.62	527	0.59	10,270	11.47	1,311	1.46	89,562
P15	101,797	90.39	9,862	8.76	433	0.38	381	0.34	152	0.13	112,625
M	86,492	85.20	9,100	8.77	1,053	1.05	3,177	3.18	1,823	1.80	101,645
SD	13,231	7.48	5,113	4.88	785	0.80	2,978	3.05	1,552	1.46	14,520

En la Tabla 7.4 se observa que, al igual que los adultos jóvenes, los adultos mayores pasan la mayor parte del tiempo observando el área del camino cuando conducen (96.5%), seguido del área izquierda de la cabina (2%). De los puntos restantes, el área derecha y el audio/clima son observados en una proporción parecida (0.70% y 0.60%). Mientras que, a diferencia de los jóvenes, el área de las piernas fue la menos observada (0.10%, 1 de cada 1,000 instancias).

De las Tablas 7.3 y 7.4 se puede concluir que el grupo de adultos mayores observó durante mayor parte de su recorrido el área del camino, seguida del área izquierda, al igual que los adultos jóvenes. Sin embargo, el porcentaje de tiempo asignado por cada grupo de edad para los PAV varía: en el caso del camino, este es observado por los adultos jóvenes un 85.20% del recorrido, mientras lo adultos mayores lo hacen un 96.54% en promedio.

Tabla 7.4. Cantidad de datos recolectados por participante del grupo de adultos mayores, donde cada unidad es un PAV detectado por cuadro de video

ID	Camino	%	Izquierda	%	Derecha	%	Piernas	%	Audio/ Clima	%	Total
P16	81,001	97.16	1,334	1.60	262	0.31	371	0.45	399	0.48	83,367
P17	80,052	98.01	976	1.19	271	0.33	30	0.04	347	0.42	81,676
P18	80,794	98.87	429	0.52	201	0.25	149	0.18	145	0.18	81,718
P19	77,471	97.50	1,018	1.28	475	0.60	192	0.24	301	0.38	79,457
P20	72,718	97.42	1,349	1.81	236	0.32	44	0.06	298	0.40	74,645
P21	86,155	97.75	894	1.01	351	0.40	264	0.30	474	0.54	88,138
P22	77,725	96.04	805	0.99	1,322	1.63	87	0.11	992	1.23	80,931
P23	74,511	93.13	4,009	5.01	924	1.15	0	0.00	563	0.70	80,007
P24	94,058	95.33	3,324	3.37	970	0.98	0	0.00	316	0.32	98,668
P25	91,652	95.42	2,614	2.72	1,468	1.53	0	0.00	314	0.33	96,048
P26	98,378	95.96	3,035	2.96	820	0.80	54	0.05	230	0.22	102,517
P27	82,018	97.62	582	0.69	420	0.50	0	0.00	1,000	1.19	84,020
P28	76,325	95.42	2,780	3.48	591	0.74	0	0.00	291	0.36	79,987
P29	75,091	95.51	1,564	1.99	671	0.85	3	0.00	1,294	1.65	78,623
P30	77,623	96.95	1,708	2.13	124	0.15	98	0.12	512	0.64	80,065
M	81,705	96.54	1,761	2.05	607	0.70	86	0.10	498	0.60	84,658
SD	7,602	1.46	1,111	1.25	416	0.46	113	0.13	333	0.42	8,101

Un ejemplo más marcado ocurre con el PAV relacionado al área de las *piernas*, el cual se considera no-crítico al conducir: mientras los adultos jóvenes lo observan un 3% del recorrido, los adultos mayores lo hacen solo un 0.10% en promedio. Las Tablas 7.3 y 7.4 son resumidas de manera gráfica en la Figura 7.1.

La comparativa del tiempo usado en cada PAV sugiere que existen diferencias en el comportamiento visual entre ambos grupos, pero este no es indicador ni del número de veces que fue visto cada punto de atención dentro de la cabina ni de la duración de la mirada durante cada uno de estos vistazos. Para obtener dichas variables, así como las condiciones bajo las que se obtuvieron (tipo de camino, velocidad del vehículo, etc.) y su posible correlación con estas, se prepararon y segmentaron los datos para su posterior análisis con el proceso explicado en sección 6.6.

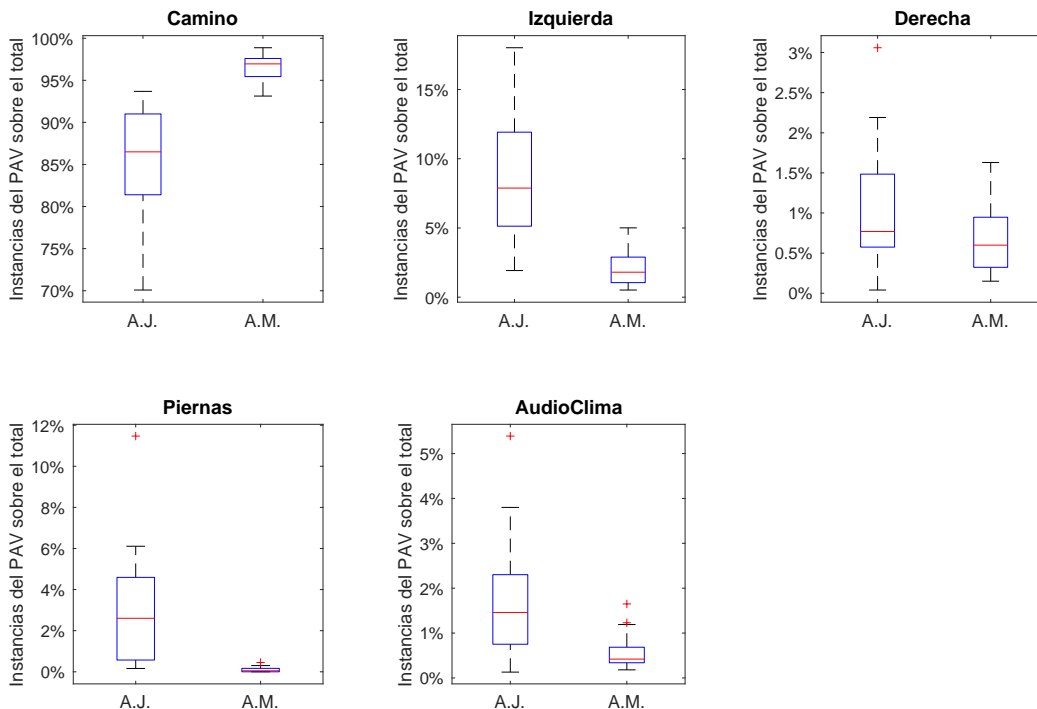


Figura 7.1. Instancias recolectadas para cada PAV por grupo de edad.

7.3 Batería de pruebas cognitivas

Los resultados de la aplicación de la batería de pruebas cognitivas se muestran en la Tabla 7.5, de la cual se obtienen las siguientes conclusiones:

- MSSE: Ambos grupos están libres de casos de demencia senil; los sujetos con menor calificación (26 puntos) requieren una revisión preventiva, de acuerdo a lo que indica el instrumento.
- TMT-A: Al grupo de los adultos mayores le tomó un 40% más de tiempo completar la prueba en comparación con los adultos jóvenes.
- TMT-B: En promedio, el grupo de adultos jóvenes tiene un resultado aceptable, mientras que el grupo de los adultos mayores le tomó un 27% más de tiempo completar la prueba a comparación de los adultos jóvenes.
- Digit Symbol Substitution: En promedio, el grupo de adultos jóvenes tiene un resultado aceptable, mientras que el grupo de los adultos mayores sustituyó un 55% menos de símbolos en comparación de los adultos jóvenes.

- Digit Span: En promedio, ambos grupos completaron la prueba de manera satisfactoria. Sin embargo, en promedio los adultos mayores recordaron un 27% menos dígitos en comparación de los adultos jóvenes.

Tabla 7.5. Resultados de la aplicación de la batería de pruebas cognitivas

Variable	Adultos jóvenes	Adultos mayores	Criterios
MMSE			27 – 30: Funcionamiento normal
<i>M</i>	28.93	28	24 – 26: Requiere revisión preventiva
<i>SD</i>	1.03	1	20 – 23: Indicios ligeros de demencia
Rango	27 – 30	26 – 29	13 – 19: Indicios moderados de demencia
			1 – 12: Demencia senil
TMT-A, tiempo (s)			
<i>M</i>	30	42.73	78 segundos o menos: Aceptable
<i>SD</i>	7.23	13.43	Más de 78 segundos: Deficiente
Rango	13 – 40	26 – 76	
TMT-B, tiempo (s)			
<i>M</i>	62.13	78.67	273 segundos o menos: Aceptable
<i>SD</i>	20.13	20.43	Más de 273 segundos: Deficiente
Rango	20 – 109	45 – 117	
Digit Symbol Substitution			
<i>M</i>	62	33.73	45 símbolos o más: Aceptable
<i>SD</i>	9.74	4.5	Menos de 45 símbolos: Deficiente
Rango	40 – 81	26 – 39	
Digit Span			
<i>M</i>	13.13	10.33	10 puntos o más: Aceptable
<i>SD</i>	3.42	2.72	Menos de 10: Deficiente
Rango	8 – 19	6 – 15	

La Tabla 7.5 revela que ambos grupos obtuvieron un resultado satisfactorio en las pruebas *TMT-A* y *TMT-B*, las cuales miden velocidad de procesamiento y flexibilidad mental, respectivamente, ambas altamente correlacionadas a un buen desempeño al conducir (Hopewell, 2002). A su vez, y como se mencionó previamente, ambos grupos presentaron un óptimo estado cognitivo, medido por el instrumento *MMSE*. En *Digit Symbol Substitution*, solo el grupo de los adultos jóvenes obtuvo un resultado satisfactorio. Por último, aunque en promedio ambos grupos obtuvieron un resultado aceptable para la prueba *Digit Span*, al tomar en cuenta las desviaciones estándar, ninguno de los dos grupos la pasa de manera satisfactoria. Los resultados anteriores sugieren que el grupo de los

adultos jóvenes posee una buena capacidad cognitiva, con 4 de 5 pruebas aprobadas, mientras que el grupo de los adultos mayores podría estar mostrando algunos indicios de declive, con 3 de las 5 pruebas terminadas satisfactoriamente.

Tabla 7.6. Comparativa de los resultados de las pruebas cognitivas entre grupos de edad

Prueba	Adultos jóvenes M (SD)	Adultos mayores M (SD)	Diferencia en el puntaje
MMSE ¹	28.93 (1.03)	28.0 (1.0)	Significativamente mayor en los adultos jóvenes, $t(28) = 2.51, p = .017944^*$
TMT-A ²	30.0 (7.23)	42.73 (13.43)	Significativamente mayor en los adultos mayores, $t(28) = -3.23, p = .003132^{**}$
TMT-B ²	62.13 (20.13)	78.67 (20.43)	Significativamente mayor en los adultos mayores, $t(28) = -2.22, p = .034411^*$
Digit Symbol Substitution ¹	62.0 (9.74)	33.73 (4.50)	Significativamente mayor en los adultos jóvenes, $t(28) = 10.11, p = .00001^{**}$
Digit Span ¹	13.13 (3.42)	10.33 (2.72)	Significativamente mayor en los adultos jóvenes, $t(28) = 2.46, p = .020265^*$

¹mayor puntaje significa mejor desempeño en la prueba; ²menor puntaje significa mejor desempeño en la prueba, * con nivel de significancia $p < .05$, ** con nivel de significancia $p < .01$

La Tabla 7.6 muestra que para todas las pruebas existen diferencias significativas cuando se comparan las calificaciones de ambos grupos; de manera general, el grupo de adultos jóvenes tuvo un mejor desempeño en todas ellas. El declive cognitivo, en sus diferentes dominios, no se presenta en todas las personas a una misma edad, pero era de esperar que, con una diferencia promedio de aproximadamente 42 años entre ambos grupos, los adultos mayores mostraran menor desempeño de capacidad cognitiva.

Los resultados anteriores y su relación con los comportamientos visuales al conducir serán explicados a detalle en secciones posteriores.

7.4 Comportamientos visuales al conducir

7.4.1 Duración de la mirada

En la Tabla 7.7 se presenta una comparativa de la duración media de la mirada hacia cada PAV entre los grupos de edad. Destaca que los adultos mayores posan durante más tiempo su atención visual sobre los PAV considerados críticos al conducir, puntualmente el *camino*, *izquierda*, y *derecha*, donde observar el primero es estrictamente necesario para

llevar a cabo el recorrido y los últimos dos se relacionan al uso de espejos retrovisores. Esto puede deberse a que los adultos mayores necesitan observar por mas tiempo un PAV para *procesar* los eventos que ahí ocurren, como la cantidad y velocidad de otros vehículos, presencia de peatones, señalamientos de tránsito, entre otros.

Sin embargo, los resultados estadísticos de la prueba *t* de Student (ver tabla 7.8), revelan que, de los puntos críticos, únicamente se encontraron diferencias significativas en la duración promedio de la mirada hacia los PAV *camino* y *derecha*. Respecto a los puntos no críticos, pese a que la duración media de la mirada de los jóvenes es más alta en estos PAV a comparación de los adultos mayores, estas diferencias no fueron estadísticamente significativas. Esto sugiere que, al ser áreas dentro de la cabina que implican dejar de observar el camino y sus alrededores cuando se observan, son brevemente atendidas por ambos grupos.

Tabla 7.7. Duración promedio de la mirada, en segundos y normalizada, hacia cada PAV por participante (continua)

ID	Camino		Izquierda		Derecha		Piernas		Audio/Clima	
P1	48.12	0.11	2.51	0.62	1.64	0.55	0.63	0.20	1.56	0.28
P2	30.42	0.06	1.26	0.00	0.82	0.22	0.97	0.30	1.45	0.25
P3	14.52	0.01	1.68	0.21	0.74	0.19	1.05	0.33	1.92	0.36
P4	11.50	0.00	2.34	0.53	1.30	0.41	0.99	0.31	1.93	0.36
P5	48.24	0.11	2.52	0.62	1.40	0.45	3.23	1.00	3.34	0.67
P6	44.25	0.10	1.85	0.29	2.22	0.77	1.86	0.58	3.85	0.79
P7	11.49	0.00	2.81	0.76	0.66	0.16	1.36	0.42	3.70	0.75
P8	47.26	0.11	2.06	0.39	0.26	0.00	0.57	0.18	0.94	0.14
P9	24.80	0.04	1.90	0.32	0.72	0.18	0.58	0.18	1.14	0.19
P10	18.12	0.02	2.46	0.59	0.69	0.17	1.13	0.35	1.36	0.24
P11	44.43	0.10	1.97	0.35	0.78	0.21	0.80	0.25	0.73	0.10
P12	20.32	0.03	1.91	0.32	1.32	0.42	0.55	0.17	2.91	0.58
P13	25.77	0.04	1.75	0.24	0.87	0.24	0.66	0.20	0.74	0.10
P14	18.67	0.02	1.65	0.19	1.10	0.33	1.00	0.31	3.95	0.81
P15	32.87	0.06	2.61	0.67	0.72	0.18	1.09	0.34	0.90	0.13
M	29.39	0.05	2.09	0.41	1.02	0.30	1.10	0.34	2.03	0.38
SD	13.43	0.04	0.42	0.21	0.47	0.19	0.66	0.21	1.15	0.26

Tabla 7.7 (continuación a la derecha)

ID	Camino		Izquierda		Derecha		Piernas		Audio/Clima	
P16	96.51	0.26	2.43	0.58	1.64	0.55	2.20	0.68	4.81	1.00
P17	136.50	0.38	1.68	0.21	1.10	0.33	0.86	0.27	0.30	0.00
P18	343.84	1.00	2.20	0.46	1.65	0.55	0.91	0.28	0.80	0.11
P19	86.79	0.23	1.76	0.25	1.48	0.48	0.97	0.30	1.07	0.17
P20	89.03	0.23	2.16	0.44	1.94	0.66	1.32	0.41	1.03	0.16
P21	131.36	0.36	1.26	0.00	1.07	0.32	0.86	0.27	2.15	0.41
P22	84.83	0.22	2.28	0.50	2.05	0.71	2.37	0.73	2.18	0.42
P23	48.85	0.11	3.29	1.00	2.34	0.82	0.00	0.00	1.14	0.19
P24	62.77	0.15	2.91	0.81	1.41	0.45	0.00	0.00	0.55	0.06
P25	64.98	0.16	2.54	0.63	2.13	0.74	0.00	0.00	0.59	0.06
P26	69.69	0.18	2.70	0.71	2.02	0.70	0.60	0.19	1.34	0.23
P27	123.11	0.34	1.28	0.01	1.08	0.32	0.00	0.00	1.33	0.23
P28	64.88	0.16	2.39	0.56	1.41	0.45	0.00	0.00	0.85	0.12
P29	58.07	0.14	1.85	0.29	2.79	1.00	0.00	0.00	1.52	0.27
P30	72.30	0.18	2.45	0.59	0.58	0.13	1.71	0.53	1.26	0.21
M	102.23	0.27	2.21	0.47	1.65	0.55	0.79	0.24	1.39	0.24
SD	72.05	0.22	0.57	0.28	0.58	0.23	0.82	0.25	1.08	0.24

Tabla 7.8. Comparativa de la duración media de la mirada (segundos) por PAV entre grupos de edad

PAV	Adultos jóvenes M (SD)	Adultos mayores M (SD)	Diferencia en la duración de la mirada
Camino	29.39 (13.90)	102.23 (72.05)	Significativamente mayor en los adultos mayores, $t(28) = -3.83, p = .000647^*$
Izquierda	2.09 (0.44)	2.21 (0.57)	Sin diferencia significativa, $t(28) = -0.68, p = .497084$
Derecha	1.02 (0.49)	1.64 (0.57)	Significativamente mayor en los adultos mayores, $t(28) = -3.22, p = .003168^*$
Piernas	2.03 (1.19)	1.00 (1.31)	Sin diferencia significativa, $t(28) = 1.13, p = .26414$
Audio/Clima	1.10 (0.69)	1.19 (0.56)	Sin diferencia significativa, $t(28) = 1.52, p = .138018$

*con nivel de significancia $p < .01$

7.4.2 Cantidad de vistazos

En la Tabla 7.9 se presenta una comparativa de la cantidad de vistazos hacia cada PAV entre los grupos de edad. De esta tabla destaca que, en promedio, el grupo de los adultos jóvenes frecuenta una mayor cantidad de veces todos los PAV a comparación de los adultos mayores. En algunos casos, no se presentaron vistazos por parte de adultos mayores hacia el PAV de las *piernas*, o apenas un par de instancias hacia el área del *audio/clima*.

Esto puede deberse a que observar el área de las *piernas* (relacionado al uso de teléfono celular) y área de *audio/clima* (relacionado también al uso de sistemas de navegación) requiere cambiar de contexto y, por lo tanto, distraerse de manera innecesaria, al no ser estos PAV críticos (o necesarios) al conducir, como si lo son el área del *camino*, *izquierda* y *derecha*.

Tabla 7.9. Cantidad de vistazos, en magnitud y normalizada, hacia cada PAV por participante (continua)

ID	Camino		Izquierda		Derecha		Piernas		Audio/Clima	
P1	56.00	0.26	82.00	0.30	30.00	0.29	44.00	0.29	6.00	0.04
P2	75.00	0.37	160.00	0.60	96.00	1.00	74.00	0.49	38.00	0.31
P3	195.00	1.00	262.00	1.00	36.00	0.35	150.00	0.99	120.00	1.00
P4	156.00	0.79	180.00	0.68	57.00	0.58	151.00	1.00	63.00	0.52
P5	42.00	0.19	17.00	0.04	15.00	0.13	14.00	0.09	11.00	0.08
P6	44.00	0.20	27.00	0.08	10.00	0.08	15.00	0.10	14.00	0.11
P7	150.00	0.76	184.00	0.70	32.00	0.31	61.00	0.40	39.00	0.32
P8	51.00	0.24	102.00	0.38	3.00	0.00	20.00	0.13	47.00	0.39
P9	99.00	0.49	121.00	0.45	36.00	0.35	64.00	0.42	107.00	0.89
P10	145.00	0.74	180.00	0.68	33.00	0.32	69.00	0.46	99.00	0.82
P11	55.00	0.26	65.00	0.23	22.00	0.20	74.00	0.49	6.00	0.04
P12	114.00	0.57	143.00	0.54	49.00	0.49	48.00	0.32	46.00	0.38
P13	90.00	0.44	171.00	0.64	31.00	0.30	9.00	0.06	11.00	0.08
P14	106.00	0.53	52.00	0.18	13.00	0.11	41.00	0.27	74.00	0.61
P15	79.00	0.39	98.00	0.36	15.00	0.13	4.00	0.03	13.00	0.10
M	97.13	0.48	122.93	0.46	31.87	0.31	55.87	0.37	46.27	0.38
SD	46.92	0.25	68.25	0.27	23.01	0.25	45.40	0.30	38.69	0.33

Tabla 7.9 (continuación a la derecha)

ID	Camino		Izquierda		Derecha		Piernas		Audio/Clima	
P16	22.00	0.08	15.00	0.04	4.00	0.01	5.00	0.03	2.00	0.01
P17	15.00	0.05	16.00	0.04	6.00	0.03	13.00	0.09	1.00	0.00
P18	6.00	0.00	6.00	0.00	3.00	0.00	5.00	0.03	6.00	0.04
P19	23.00	0.09	15.00	0.04	8.00	0.05	10.00	0.07	5.00	0.03
P20	21.00	0.08	16.00	0.04	3.00	0.00	6.00	0.04	1.00	0.00
P21	17.00	0.06	19.00	0.05	8.00	0.05	14.00	0.09	3.00	0.02
P22	24.00	0.10	10.00	0.02	16.00	0.14	11.00	0.07	1.00	0.00
P23	40.00	0.18	33.00	0.11	10.00	0.08	0.00	0.00	13.00	0.10
P24	39.00	0.17	31.00	0.10	18.00	0.16	0.00	0.00	15.00	0.12
P25	36.00	0.16	27.00	0.08	18.00	0.16	0.00	0.00	18.00	0.14
P26	36.00	0.16	32.00	0.10	10.00	0.08	10.00	0.07	1.00	0.00
P27	17.00	0.06	15.00	0.04	10.00	0.08	0.00	0.00	21.00	0.17
P28	30.00	0.13	31.00	0.10	11.00	0.09	0.00	0.00	10.00	0.08
P29	34.00	0.15	23.00	0.07	7.00	0.04	0.00	0.00	26.00	0.21
P30	24.00	0.10	19.00	0.05	5.00	0.02	8.00	0.05	1.00	0.00
<i>M</i>	25.60	0.10	20.53	0.06	9.13	0.07	5.47	0.04	8.27	0.06
<i>SD</i>	9.94	0.05	8.51	0.03	4.97	0.05	5.26	0.03	8.40	0.07

Observando los promedios por grupo, las diferencias son muy notorias para todos los PAV: no solo son mas frecuentados en todos los casos por el grupo de adultos jóvenes, si no que lo hacen en razones que van desde 5:1 hasta 10:1, siendo los puntos no críticos al conducir donde se marca más esta diferencia de comportamientos. La Tabla 7.10 revela que todas estas diferencias son, además, estadísticamente significativas. En complemento a la discusión de la sección anterior, estos resultados sugieren que existe una mecánica de compensación por parte de los adultos mayores: al tener que observar durante mas tiempo los PAV necesarios durante la conducción, su número de interacciones se ve reducida con estos mismos y, por lo tanto, los no críticos al conducir.

Tabla 7.10. Comparativa de la cantidad de vistazos hacia cada PAV entre grupos de edad

PAV	Adultos jóvenes M (SD)	Adultos mayores M (SD)	Diferencia en la duración de la mirada
Camino	97.13 (46.92)	25.60 (9.94)	Significativamente mayor en los adultos jóvenes, $t(28) = 5.76, p = .00001^*$
Izquierda	122.93 (68.25)	20.53 (8.51)	Significativamente mayor en los adultos jóvenes, $t(28) = 5.73, p = .00001^*$
Derecha	31.87 (23.01)	9.13 (4.97)	Significativamente mayor en los adultos jóvenes, $t(28) = 3.73, p = .000854^*$
Piernas	46.27 (38.69)	1.40 (1.88)	Significativamente mayor en los adultos jóvenes, $t(28) = 4.27, p = .000202^*$
Audio/Clima	55.87 (45.40)	12.33 (5.91)	Significativamente mayor en los adultos jóvenes, $t(28) = 3.69, p = .0.000935^*$

*Con nivel de significancia $p < .01$

7.4.3 Similitud de comportamientos visuales entre grupos de edad

Si bien la comparación estadística de los resultados de las Tablas 7.7 y 7.9 establece que existen diferencias significativas entre ambos grupos de edad para la cantidad de vistazos y duración media de la mirada hacia algunos PAV, la normalización de estas variables en el rango [0 1] exhibe que los comportamientos visuales de cada grupo, aun cuando difieren en magnitud, también poseen similitudes.

En las gráficas a) y b) de la Figura 7.2 puede observarse que, para el área del *camino*, los individuos que observan durante mas tiempo este PAV, tienden a reincidir menos veces con el área; por el contrario, aquellos que tienden a observar mas veces el área, lo hacen con miradas de menor duración; lo anterior puede interpretarse como un mecanismo de *compensación* por parte de los conductores para asignarle mayor atención visual a lo largo del recorrido, ya que se trata del PAV mas importante durante la conducción. Este comportamiento, para ambos grupos, puede expresarse también como una correlación fuertemente negativa.

Las graficas c) y d) presentan esta misma comparativa para el resto de los PAV, y aunque las tendencias no son igual de marcadas que en el caso del área *camino*, puede apreciarse que *izquierda* es el PAV mas visto, mientras que *derecha*, *piernas*, así como *audio/clima*, tienden a concentrarse en el cuadrante compuesto por la menor cantidad de vistazos y duración media de la mirada, lo cual puede ser explicado en que, independiente a

la edad del conductor, son evitadas en cantidad y duración por el peligro que podría suponer asignarles una mayor cantidad de atención visual. Estos comportamientos, para ambos grupos, pueden expresarse también como una correlación moderadamente positiva.

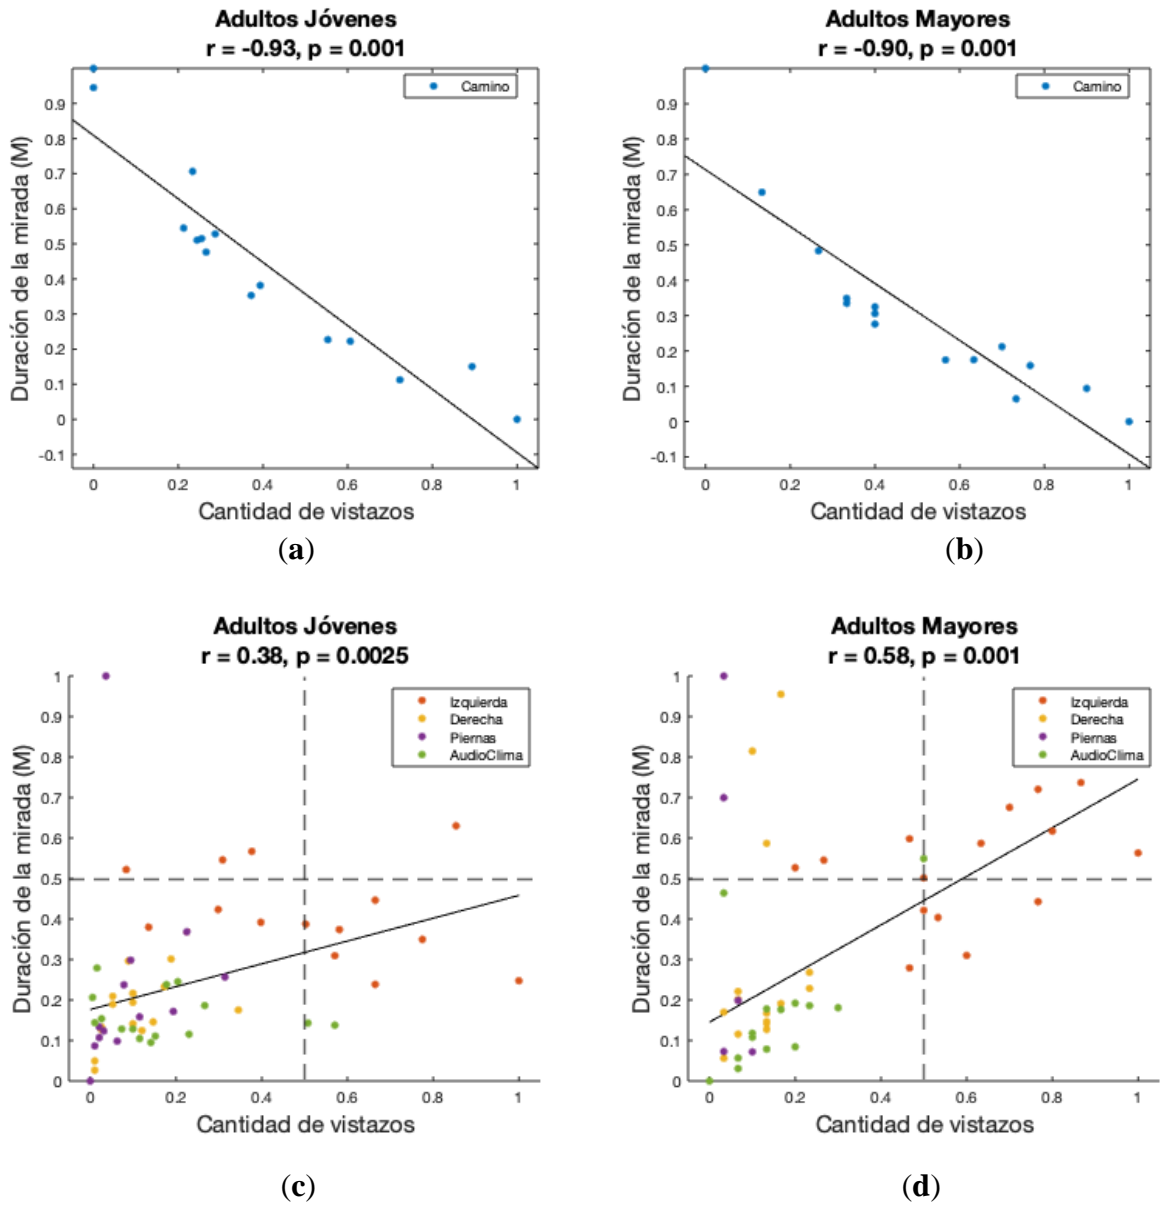


Figura 7.2. Comparativa para la cantidad de vistazos y duración media de la mirada por participante con respecto a: PAV del camino en **a)** los jóvenes y **b)** adultos mayores; y los PAV restantes en **c)** los jóvenes y **d)** adultos mayores.

7.5 Relación entre comportamientos visuales y pruebas cognitivas

En la sección 7.3 se estableció que existen diferencias significativas entre ambos grupos de edad para cada examen que forma parte de la batería de pruebas cognitivas, y en la sección 7.4 se analizaron las diferencias significativas para la duración de la mirada y cantidad de vistazos hacia cada PAV que, así mismo, existen entre adultos jóvenes y adultos mayores. Tomando en cuenta los resultados de las secciones mencionadas, se exploró la posible correlación entre el resultado de cada prueba cognitiva y las variables de duración de la mirada y cantidad de vistazos hacia cada PAV.

7.5.1 Duración de la mirada

Utilizando los resultados de cada participante en cada una de las pruebas cognitivas como variable X, y como variable Y la duración media de la mirada de cada participante hacia cada uno de los PAV, provenientes de la Tabla 7.7, se calcularon los coeficientes de correlación de Pearson para medir la fuerza y dirección de la relación entre ambas variables, cuyos resultados son presentados en la Tabla 7.11. De estos resultados, las correlaciones que cuentan con significancia estadística $p < .05$ son ilustradas en la Figura 7.3.

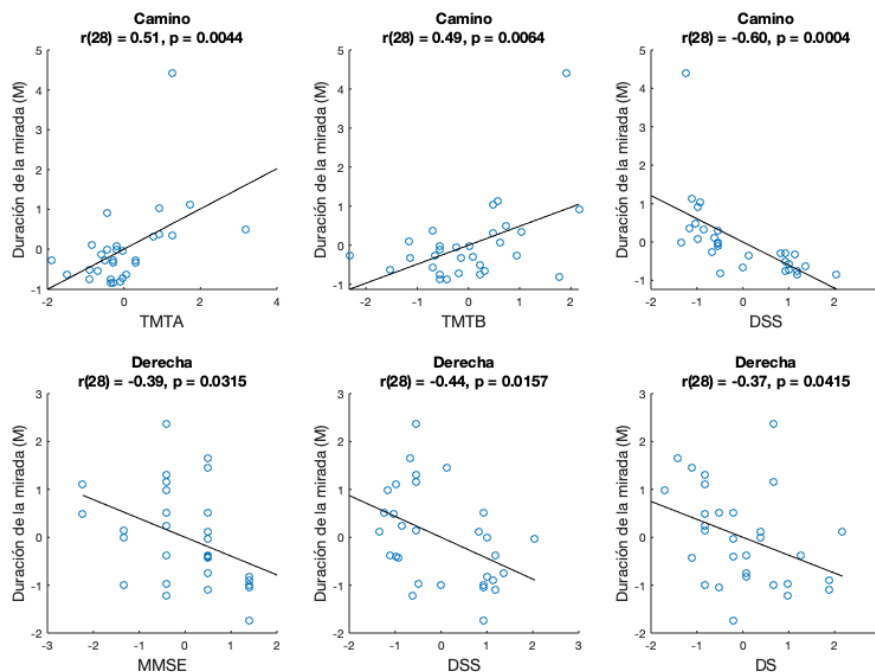


Figura 7.3. Correlaciones entre la duración media de la mirada por PAV y el resultado de las pruebas cognitivas.

Tabla 7.11. Resultados de la relación entre la duración media de la mirada para cada PAV y el resultado de cada prueba cognitiva

	Camino	Izquierda	Derecha	Piernas	Audio/Clima
MMSE	Resultado no significativo, $p = .7094$	Resultado no significativo, $p = .3280$	Correlación moderadamente positiva, $p = .0315$	Resultado no significativo, $p = .4365$	Resultado no significativo, $p = .9814$
TMT-A	Correlación moderadamente positiva, $p = .0044$	Resultado no significativo, $p = .7106$	Resultado no significativo, $p = .2369$	Resultado no significativo, $p = .2247$	Resultado no significativo, $p = .2230$
TMT-B	Correlación moderadamente positiva, $p = .0064$	Resultado no significativo, $p = .4381$	Resultado no significativo, $p = .8584$	Resultado no significativo, $p = .3466$	Resultado no significativo, $p = .9128$
Digit Symbol Substitution	Correlación moderadamente negativa, $p = .0004$	Resultado no significativo, $p = .9928$	Correlación moderadamente positiva, $p = .0157$	Resultado no significativo, $p = .0905$	Resultado no significativo, con $p < .6726$
Digit Span	Resultado no significativo, $p = .1328$	Resultado no significativo, $p = .5627$	Correlación moderadamente positiva, $p = .0415$	Resultado no significativo, $p = .1667$	Resultado no significativo, $p < .1244$

Una interpretación de las correlaciones presentes en la Figura 7.3 es que los individuos con peores índices de velocidad de procesamiento (TMT-A), flexibilidad mental (TMT-B), así como atención y concentración (DSS) observan por más tiempo el PAV *camino*. A su vez, aquellos individuos con peores índices de estado cognitivo (MMSE), atención y concentración (DSS), y memoria de trabajo (DS) tienden a observar por más tiempo el PAV *derecha*. En la sección 7.4.1 se estableció que existe una diferencia significativa en la duración media de la mirada entre ambos grupos en los PAV *camino* y *derecha*, en la cual los adultos mayores tienden a observar por más tiempo estos puntos de cabina, lo cual sugiere que todos los instrumentos de la batería de pruebas cognitivas pueden describir en algún grado el comportamiento visual de la duración media de la mirada.

7.5.2 Cantidad de vistazos

Al igual que con la duración de la mirada, se utilizaron los resultados de cada instrumento de la batería de pruebas cognitivas como variable X, y la cantidad de vistazos hacia cada uno de los PAV por participante, provenientes de la Tabla 7.9, como variable Y, con la finalidad de calcular los coeficientes de correlación de Pearson entre ambas variables. Los resultados se presentan en la Tabla 7.12. De estos resultados, las correlaciones que cuentan con significancia estadística $p < .05$ son ilustradas en la Figura 7.4.

Tabla 7.12. Resultados de la relación entre cantidad de vistazos para cada PAV y el resultado de pruebas cognitivas

	Camino	Izquierda	Derecha	Piernas	Audio/Clima
MMSE	Resultado no significativo, $p < .3480$	Resultado no significativo, $p < .1949$	Resultado no significativo, $p < .3229$	Resultado no significativo, $p < .3731$	Resultado no significativo, $p < .5739$
TMT-A	Correlación moderadamente negativa, $p = 0.0338$	Correlación moderadamente negativa, $p = 0.0176$	Resultado no significativo, $p = 0.0518$	Resultado no significativo, $p = 0.3154$	Resultado no significativo, $p = 0.1643$
TMT-B	Resultado no significativo, $p = 0.6283$	Resultado no significativo, $p = 0.5789$	Resultado no significativo, $p = .1909$	Resultado no significativo, $p = .9982$	Resultado no significativo, $p = .4526$
Digit Symbol Substitution	Correlación moderadamente positiva, $p = 0.0001$	Correlación moderadamente positiva, $p = 0.0001$	Correlación moderadamente positiva, $p = 0.0005$	Correlación moderadamente positiva, $p = 0.0139$	Correlación moderadamente positiva, $p = 0.0046$
Digit Span	Resultado no significativo, $p = .0551$	Resultado no significativo, $p = .1457$	Resultado no significativo, $p = .2581$	Resultado no significativo, $p = .1197$	Resultado no significativo, $p = .0636$

En la Tabla 7.12 se establece que no se encontró una relación significativa entre los instrumentos *MMSE*, *TMT-B*, y *Digit Span* con la cantidad de vistazos hacia cada uno de los PAV.

Por otro lado, los individuos con una mejor velocidad de procesamiento (característico también de los adultos jóvenes, y medido mediante *TMT-A*) tienden a fijar más veces su atención visual sobre el *camino* y el área *izquierda* (Ver Figura 7.4).

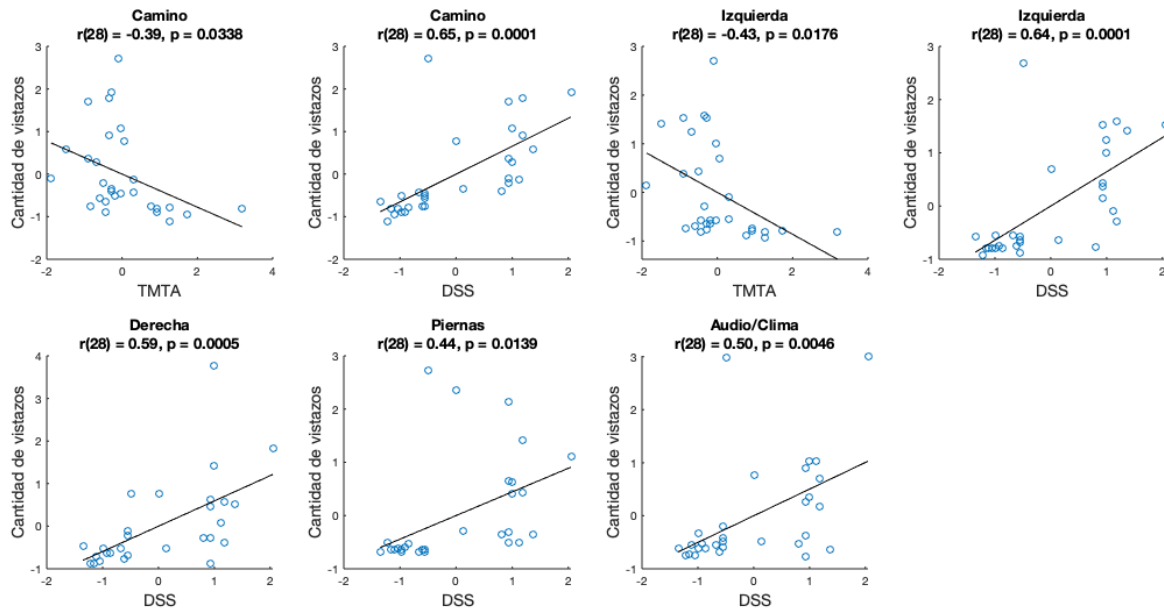


Figura 7.4. Correlaciones entre la cantidad de vistazos por PAV y el resultado de las pruebas cognitivas.

A su vez, la atención y concentración, medidas mediante el instrumento *Digit Symbol Substitution*, tiene una correlación moderadamente positiva con la cantidad de vistazos hacia cada uno de los PAV, tal como se ilustra en la Figura 7.4. Una interpretación de estos resultados que los individuos con un mejor índice en esta prueba (característico de los adultos jóvenes) tienden a cambiar constantemente de PAV. Al igual que *TMT-A*, el resultado de *DSS* tiene correlación tanto con la duración de la mirada como con la cantidad de vistazos.

En la sección 7.4.2 se estableció que existe una diferencia significativa para la cantidad de vistazos hacia todos los PAV entre el grupo de adultos jóvenes y el de adultos mayores, lo cual sugiere que los instrumentos *TMT-A* y *DSS* pueden describir en algún grado este comportamiento visual.

7.6 Relación entre los comportamientos visuales y el contexto de la conducción

Además del análisis sobre las variables *cantidad de vistazos* y *duración de la mirada* en relación al resultado de la batería de pruebas cognitivas, se llevaron a cabo

análisis comparando comportamientos visuales contra variables asociadas al contexto de la conducción, por grupos de edad.

7.6.1 Comportamientos visuales y velocidad del vehículo

Las gráficas a y b de Figura 7.5 muestran que, al aumentar la velocidad del vehículo, los sujetos tendían a conservar su mirada por más tiempo en el *camino*. En consecuencia, conforme se observa por más tiempo el área del *camino*, la atención visual “sale” menos de este PAV, por lo que la cantidad de vistazos hacia otros puntos de atención dentro de la cabina (y por lo tanto la reincidencia al área del camino) se reduce, tal como se demuestra en las gráficas c) y d) de la Figura 7.5 que correlacionan la cantidad de vistazos con la velocidad.

Las descripciones anteriores dan lugar a un análisis de tipo correlación entre la cantidad de vistazos y duración media de la mirada contra la velocidad del vehículo, cuyos resultados son exhibidos en la Tabla 7.13; aquí se establece que en tres de los cuatro comportamientos esperados existen correlaciones de naturaleza fuerte, y una moderada para el comportamiento restante. Se concluye, por lo tanto, que independientemente del grupo de edad, cuanto mas rápido se conduce:

- la atención se concentra menos en otros PAV diferentes al *camino* (*correlación negativa*, cuando el valor de una variable se incrementa, en la otra se reduce)
- la duración de la mirada en el PAV *camino* aumenta (*correlación positiva*, cuando el valor de una variable se incrementa, en la otra variable sucede lo mismo)

Tabla 7.13. Resultados del análisis del coeficiente de correlación de Pearson

	Velocidad - Cantidad de vistazos	Velocidad – Duración media de la mirada
Adultos Jóvenes	Correlación moderadamente negativa, $r(13) = -.72, p < .05$	Correlación fuertemente positiva, $r(13) = .94, p < .05$
Adultos Mayores	Correlación fuertemente negativa, $r(13) = -.88, p < .05$	Correlación fuertemente positiva, $r(13) = .96, p < .05$

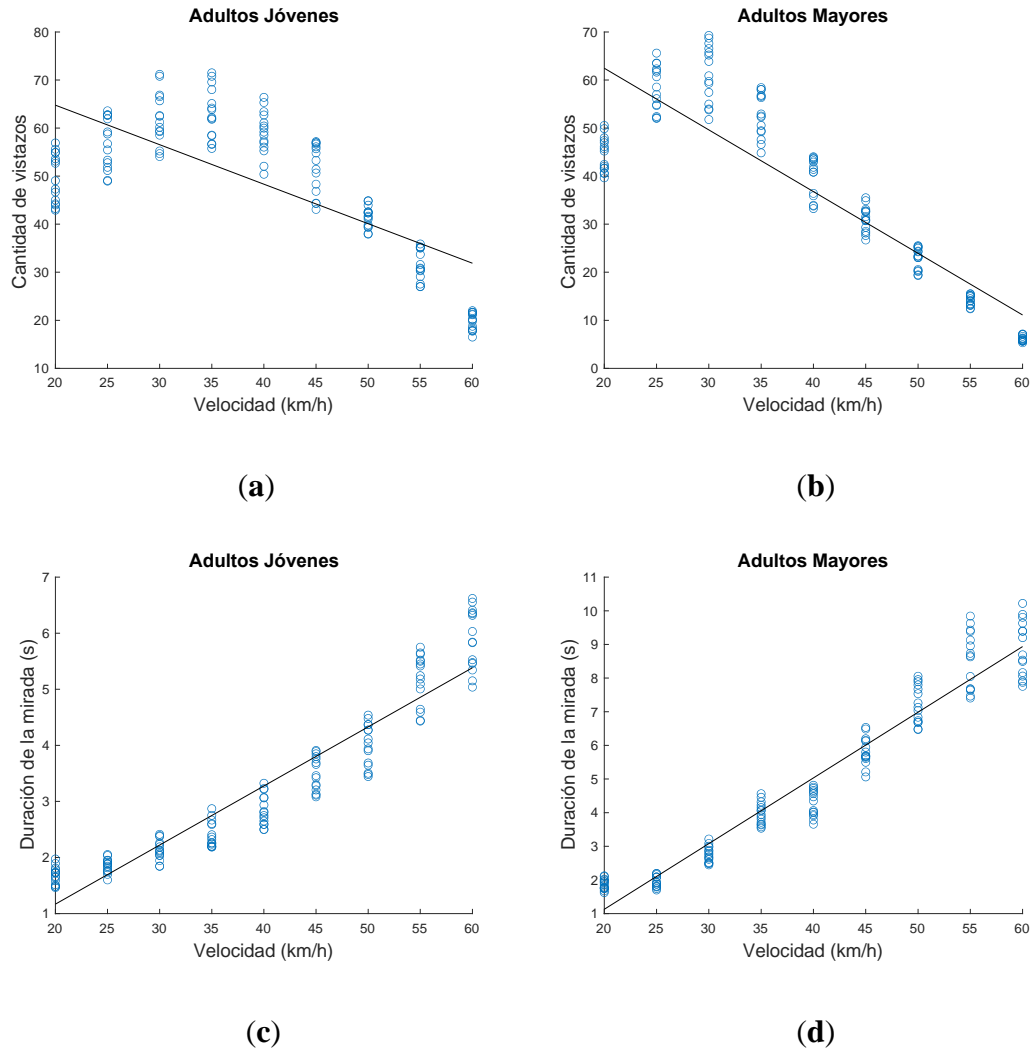


Figura 7.5. Relación entre velocidad y comportamientos visuales hacia el área del camino con respecto a: cantidad de vistazos en **a)** los jóvenes y **b)** adultos mayores; y duración de la mirada en **c)** los jóvenes y **d)** adultos mayores.

7.6.2 Comportamientos visuales y variables del contexto de la conducción

Además de la velocidad del vehículo, otras variables recolectadas y asociadas al contexto de la conducción fueron la ubicación del vehículo, acción por parte del conductor, y presencia o ausencia del pasajero en el asiento del copiloto. Las medias de la duración de la mirada, y cantidad de vistazos a cada PAV, por grupo de edad, y en relación a estas variables, son presentadas en las Tablas 7.14 y 7.15.

Tabla 7.14. Duración media de la mirada, en segundos, asociada a variables del contexto de la conducción (continua)

		Residencial				Arterial				Cambio carril derecho				Cambio carril izquierdo			
		CP		SP		CP		SP		CP		SP		CP		SP	
		AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ
Camino	SUM	468.16	294.48	380.78	190.27	875.99	515.64	992.30	356.31	47.53	35.54	50.67	17.07	22.61	28.46	40.12	31.88
	M	31.21	19.63	25.39	12.68	58.40	34.38	66.15	23.75	3.40	2.54	3.90	1.71	1.51	1.90	2.67	2.13
	SD	9.39	8.18	5.05	4.99	15.07	17.47	25.62	10.77	0.64	0.81	3.79	0.59	1.14	0.69	0.59	0.64
Audio/Clima	SUM	8.95	12.27	7.07	9.47	14.91	19.94	22.06	14.25	1.29	2.41	3.02	1.66	0.00	0.00	0.00	0.24
	M	0.81	0.94	0.64	0.73	0.99	1.42	1.47	1.02	0.64	0.40	1.01	0.55	0.00	0.00	0.00	0.24
	SD	0.67	0.52	0.37	0.42	0.59	1.55	1.07	0.82	0.03	0.21	0.76	0.36	0.00	0.00	0.00	0.00
Derecha	SUM	20.03	18.66	21.15	14.21	25.62	13.83	16.70	9.49	0.00	3.05	0.00	0.67	0.00	0.00	0.00	0.17
	M	1.54	1.33	1.41	1.01	1.97	0.92	1.39	0.86	0.00	0.51	0.00	0.67	0.00	0.00	0.00	0.17
	SD	0.78	0.63	1.22	0.55	2.20	0.61	0.66	0.89	0.00	0.49	0.00	0.00	0.00	0.00	0.00	0.00
Izquierda	SUM	20.44	22.36	34.87	39.93	34.42	28.31	30.01	32.20	0.00	0.92	0.80	0.68	31.78	8.96	24.18	18.13
	M	1.46	1.49	2.32	2.66	2.29	1.89	2.00	2.15	0.00	0.92	0.80	0.34	2.27	0.75	1.61	1.51
	SD	1.20	0.35	0.98	0.81	0.61	0.93	0.94	0.74	0.00	0.00	0.00	0.15	0.64	0.53	0.48	0.80
Piernas	SUM	0.00	15.02	0.00	7.34	1.34	23.95	13.72	37.71	0.00	0.00	0.00	0.00	0.00	0.58	0.00	2.57
	M	0.00	1.07	0.00	0.67	1.34	1.71	1.72	2.51	0.00	0.00	0.00	0.00	0.00	0.29	0.00	0.86
	SD	0.00	0.84	0.00	0.48	0.00	1.53	1.40	1.80	0.00	0.00	0.00	0.00	0.00	0.02	0.00	0.60

Tabla 7.14. (continuación a la derecha)

Estacionarse		Linea recta				Semáforo				Vuelta derecha				Vuelta izquierda					
CP		SP		CP		SP		CP		SP		CP		SP		CP		SP	
AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ
129.96	324.47	17.61	13.67	556.80	398.28	474.83	302.05	400.38	213.99	361.84	165.86	84.79	56.75	69.57	42.90	40.33	24.31	47.02	22.55
9.28	21.63	2.20	1.52	37.12	26.55	31.66	20.14	26.69	14.27	24.12	11.06	5.65	3.78	4.97	2.86	2.69	1.62	3.13	1.50
2.35	21.03	2.39	0.94	5.19	8.28	2.88	6.22	9.84	7.00	5.58	6.44	0.86	1.26	1.31	1.03	1.31	0.79	1.33	0.66
3.96	15.15	0.60	0.16	7.53	7.29	4.31	7.87	15.03	20.62	23.53	15.44	3.49	13.62	1.59	10.79	0.54	3.25	0.57	3.61
0.57	1.17	0.15	0.16	0.68	0.61	0.48	0.66	1.16	1.59	1.57	1.19	0.58	1.14	0.79	0.98	0.54	0.65	0.57	0.52
0.45	1.22	0.02	0.00	0.67	0.20	0.22	0.34	0.59	1.42	1.07	0.89	0.23	0.50	0.30	0.65	0.00	0.42	0.00	0.50
21.59	19.73	14.50	0.99	8.42	9.69	17.34	12.10	18.11	16.01	16.46	10.04	3.86	7.77	0.00	3.99	1.12	8.35	5.96	5.67
1.96	1.52	1.21	0.99	0.70	0.65	1.33	0.93	1.51	1.14	1.37	0.91	1.29	0.97	0.00	0.80	0.56	1.39	1.49	0.81
0.92	1.22	0.57	0.00	0.33	0.44	1.89	0.58	0.61	0.80	0.78	0.99	0.63	0.59	0.00	0.47	0.56	1.32	1.87	0.62
0.00	12.19	0.00	9.35	22.61	21.80	34.97	26.33	10.40	26.67	16.04	30.58	1.02	9.32	2.71	13.96	25.24	35.18	29.42	37.75
0.00	1.02	0.00	1.34	1.51	1.45	2.33	1.76	2.60	1.78	2.67	2.35	0.34	0.85	0.68	1.27	1.94	2.35	1.96	2.52
0.00	0.63	0.00	1.92	1.06	0.73	2.25	0.72	0.56	0.72	1.16	1.43	0.15	0.46	0.60	1.30	0.97	0.76	0.73	0.71
0.00	10.13	0.00	0.00	0.00	8.65	8.59	13.19	1.34	22.88	15.16	41.92	0.00	0.00	0.00	1.44	0.00	4.75	0.00	1.16
0.00	1.45	0.00	0.00	0.00	1.08	1.72	1.10	1.34	1.63	2.17	2.79	0.00	0.00	0.00	0.72	0.00	0.95	0.00	0.39
0.00	1.54	0.00	0.00	0.00	0.55	1.74	1.23	0.00	1.24	1.70	2.34	0.00	0.00	0.00	0.29	0.00	0.91	0.00	0.40

CP = Con pasajero; SP = Sin pasajero; AM = Adulto mayor; AJ = Adulto joven

Tabla 7.15. Cantidad de vistazos, asociada a variables del contexto de la conducción
(continua)

		Residencial				Arterial				Cambio carril derecho				Cambio carril izquierdo			
		CP		SP		CP		SP		CP		SP		CP		SP	
		AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ
Camino	<i>SUM</i>	105	256	171	358	192	444	227	705	37	41	16	17	54	59	86	88
	<i>M</i>	7.0	17.1	11.4	23.9	12.8	29.6	15.1	47.0	2.6	2.9	1.2	1.7	3.6	3.9	5.7	5.9
	<i>SD</i>	1.3	9.4	2.1	10.2	3.5	13.0	5.3	22.6	1.2	1.5	0.4	0.8	1.5	2.1	1.5	1.9
Audio/Clima	<i>SUM</i>	22	152	23	91	71	378	68	217	3	8	3	3	0	0	0	1
	<i>M</i>	2.0	11.7	2.1	7.0	4.7	27.0	4.5	15.5	1.5	1.3	1.0	1.0	0.0	0.0	0.0	1.0
	<i>SD</i>	1.3	7.9	1.1	6.9	3.6	18.8	2.5	16.6	0.7	0.5	0.0	0.0	0.0	0.0	0.0	0.0
Derecha	<i>SUM</i>	26	100	37	65	45	223	40	94	0	11	0	1	0	0	0	3
	<i>M</i>	2.0	7.1	2.5	4.6	3.5	14.9	3.3	8.5	0.0	1.8	0.0	1.0	0.0	0.0	0.0	3.0
	<i>SD</i>	0.8	3.2	1.1	3.1	2.2	12.3	2.1	8.5	0.0	1.6	0.0	0.0	0.0	0.0	0.0	0.0
Izquierda	<i>SUM</i>	40	244	93	335	87	504	95	786	0	1	2	3	28	24	44	34
	<i>M</i>	2.9	16.3	6.2	22.3	5.8	33.6	6.3	52.4	0.0	1.0	2.0	1.5	2.0	2.0	2.9	2.8
	<i>SD</i>	1.8	8.1	2.4	11.8	2.2	20.2	4.9	34.0	0.0	0.0	0.0	0.7	1.0	1.1	1.1	2.0
Piernas	<i>SUM</i>	0	75	0	66	1	218	19	331	0	0	0	0	0	2	0	3
	<i>M</i>	0.0	5.4	0.0	6.0	1.0	15.6	2.4	22.1	0.0	0.0	0.0	0.0	0.0	1.0	0.0	1.0
	<i>SD</i>	0.0	5.8	0.0	6.8	0.0	15.5	1.8	17.6	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0

Tabla 7.15. (continuación a la derecha)

Estacionarse		Linea recta				Semáforo				Vuelta derecha				Vuelta izquierda					
CP		SP		CP		SP		CP		SP		CP		SP		CP		SP	
AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ	AM	AJ
14	56	8	16	281	485	384	698	107	298	209	487	44	51	15	38	82	90	149	152
1.0	3.7	1.0	1.8	18.7	32.3	25.6	46.5	7.1	19.9	13.9	32.5	2.9	3.4	1.1	2.5	5.5	6.0	9.9	10.1
0.0	3.1	0.0	2.0	3.2	11.3	2.2	18.3	3.6	8.7	4.0	15.1	0.5	1.9	0.3	2.0	1.2	1.6	1.7	2.6
9	52	4	1	27	243	17	185	42	200	60	93	10	32	3	22	1	6	1	9
1.3	4.0	1.0	1.0	2.5	20.3	1.9	15.4	3.2	15.4	4.0	7.2	1.7	2.7	1.5	2.0	1.0	1.2	1.0	1.3
0.5	2.6	0.0	0.0	3.2	15.2	0.9	18.0	1.7	11.2	2.4	5.9	0.5	1.5	0.7	1.3	0.0	0.4	0.0	0.8
15	47	12	1	19	142	26	102	33	103	38	35	5	14	0	9	2	13	4	9
1.4	3.6	1.0	1.0	1.6	9.5	2.0	7.8	2.8	7.4	3.2	3.2	1.7	1.8	0.0	1.8	1.0	2.2	1.0	1.3
0.5	2.5	0.0	0.0	1.2	10.4	0.7	7.0	2.0	4.8	2.2	3.4	1.2	0.7	0.0	0.8	0.0	1.3	0.0	0.5
0	22	0	11	59	539	79	756	10	131	23	298	3	19	4	19	38	71	71	119
0.0	1.8	0.0	1.6	3.9	35.9	5.3	50.4	2.5	8.7	3.8	22.9	1.0	1.7	1.0	1.7	2.9	4.7	4.7	7.9
0.0	1.4	0.0	1.5	2.3	21.1	3.1	30.9	1.0	7.2	3.0	16.5	0.0	0.9	0.0	1.0	1.2	1.6	2.1	1.9
0	22	0	0	0	95	7	112	1	180	13	284	0	0	0	3	0	8	0	10
0.0	3.1	0.0	0.0	0.0	11.9	1.4	9.3	1.0	12.9	1.9	18.9	0.0	0.0	0.0	1.5	0.0	1.6	0.0	3.3
0.0	2.4	0.0	0.0	0.0	9.0	0.5	8.8	0.0	11.5	1.5	15.2	0.0	0.0	0.0	0.7	0.0	0.9	0.0	3.2

CP = Con pasajero; SP = Sin pasajero; AM = Adulto mayor; AJ = Adulto joven

En las tablas anteriores puede observarse que algunas acciones por parte del conductor, como los cambios de carril a la izquierda y derecha, tienen poco impacto en la interacción del sujeto con PAV diferentes al *camino*, tanto en cantidad de vistazos como en duración de la mirada, independientemente del grupo al que pertenezca. De manera similar, los adultos mayores tienden a interactuar poco, en duración y cantidad de vistazos, con los PAV fuera del *camino* al dar vueltas a la izquierda, derecha y estacionarse.

Al ir conduciendo en línea recta, los adultos mayores llevan a cabo una menor cantidad de vistazos hacia el área del *camino*, lo cual se ve reflejado en duraciones más elevadas al área en comparación de los adultos jóvenes, quienes tienden a voltear más hacia otros PAV y, por lo tanto, asignan miradas más cortas hacia el *camino*.

Por otro lado, la duración de la mirada hacia el *camino* aumenta para ambos grupos cuando se pasa de conducir en calles residenciales a arteriales (véase Tabla 7.14); este resultado coincide con el obtenido durante el estudio en el que se utilizó la primera versión del sistema, y que a la vez puede asociarse a las correlaciones descritas en la sección 7.6.1, donde se establece que al conducirse a mayor velocidad (característico de las vías arteriales) la atención visual del conductor hacia esta área aumenta.

Un comportamiento en particular, observado durante la sesión de manejo en el estudio, se dio cuando los conductores se encontraban detenidos en semáforos en rojo: estos tendían a utilizar con más frecuencia el teléfono celular cuando no contaban con la presencia de un pasajero. Para estudiar este comportamiento, corroborado mediante las grabaciones de los recorridos y apoyado de los resultados de la Tabla 7.15, se consideró que la orientación de la cabeza hacia el área de las piernas funciona como estimación del uso del teléfono celular. Para corroborar si la presencia de un pasajero impacta la cantidad de vistazos hacia el área de las piernas, se recurrió al uso de la prueba de los rangos con signo de Wilcoxon para encontrar diferencias significativas dentro de los grupos bajo dos tratamientos distintos (con pasajero y sin pasajero). La representación gráfica de este comportamiento puede ser observada en la Figura 7.6.




Figura 7.6. Cantidad de vistazos por participante hacia el área de las piernas al estar detenidos en semáforos en rojo.

Como se puede apreciar en la gráfica, y apoyado en el resultado de la prueba de los rangos con signo de Wilcoxon, la cantidad de vistazos hacia el área de las piernas es significativamente mayor ($W = 48$, $p < .05$) cuando no hay interacción con el pasajero. Adicionalmente (no ilustrado), la duración de la mirada es también significativamente mayor ($W = 28$, $p < .05$) cuando no hay interacción con el pasajero. La Figura 7.6 ilustra también que los adultos mayores ven con menos frecuencia puntos de la cabina que no son necesarios para conducir (como es el caso del área de las *piernas*) en comparación a los adultos jóvenes.

7.7 Conclusiones

En su segunda versión, el sistema de recolección de datos portátil permitió capturar con más facilidad, robustez y precisión conjuntos de datos sobre los comportamientos de manejo, compuestos por los comportamientos visuales del conductor y el contexto del vehículo; estos últimos permitieron estudiar si el tipo de camino, la velocidad a la que se conduce, o la interacción con un pasajero generan o forman parte de patrones de atención visual a puntos específicos dentro de la cabina del vehículo.

Los resultados del estudio son consistentes con los hallazgos establecidos en otras investigaciones: en Wikman & Summala, 2005, se encontró que los sujetos de mayor edad, y con un mal desempeño en pruebas cognitivas como *TMT-A*, tienden a apartar durante más tiempo la mirada del camino cuando se ven necesitados a situar su atención en otros puntos

dentro de cabina; Fancello et al., reportan que el declive cognitivo que acompaña el envejecimiento ocasiona que los adultos mayores fijen su mirada en menos ocasiones pero por mas tiempo fuera del camino para capturar por completo los estímulos visuales a su alrededor, como otros vehículos y señalamientos, tal como sucedió durante la sesión de manejo de este estudio.

Lo anterior indica que el uso multimodal de sensores, aunado a técnicas de inteligencia artificial, puede ser utilizado para estudiar los comportamientos visuales mientras se conduce, de la misma manera que se ha hecho con el uso de otras tecnologías (grabaciones de video, *eye-trackers*), reportadas como instrumentos de recolección de datos en los estudios mencionados anteriormente.

Capítulo VIII

Conclusión

En esta tesis se presentó un novedoso sistema de sensado multimodal inteligente, utilizado para detectar y cuantificar la orientación de la cabeza en sus tres grados de libertad. El estudio de factibilidad, así como el estudio naturalista, demostraron que el sistema de sensado es útil para recolectar datos durante la conducción y lo suficientemente preciso para inferir hacia que punto de cabina dirige el conductor su atención. Estos datos fueron posteriormente procesados y analizados para estudiar las diferencias en los comportamientos visuales entre dos grupos de edad, así como la posible correlación de estos comportamientos con el resultado de pruebas cognitivas y variables relacionadas al contexto de la conducción. De lo anterior, y a lo largo de este trabajo, se concluyó que:

- Los comportamientos visuales (duración de la mirada y cantidad de vistazos a cada PAV), se ven afectados, a veces de manera significativa, por variables relacionadas al contexto de la conducción, tales como la ubicación geográfica, velocidad a la que se conduce, y la presencia o ausencia de un pasajero en el asiento del copiloto, lo cual contesta la Pregunta de Investigación 1 (“¿Cómo los comportamientos visuales se relacionan a variables del contexto de la conducción?”).
- Entre grupos de edad, los comportamientos visuales varían de manera significativa. En general, los adultos mayores prestan más atención al área del camino mientras conducen, y los adultos jóvenes tienden a interactuar en mayor medida con los demás puntos de atención dentro de cabina, como el área de las piernas. Estos resultados contestan la Pregunta de Investigación 2 (“¿Cómo difieren los comportamientos visuales entre grupos de edad?”).
- Existen correlaciones significativas entre los comportamientos visuales y el resultado de algunas pruebas cognitivas, tales como *Trail Making Test A* y *Digit Symbol*

Substitution. Estos resultados contestan la Pregunta de Investigación 3 (“¿Cómo se relacionan los comportamientos visuales dentro de la cabina con una o más variables asociadas a la aptitud para conducir?”).

Se cumplieron los objetivos específicos planteados en el primer capítulo para contestar cada una de las preguntas de investigación, con lo que se consiguió alcanzar el objetivo general de esta tesis (“Desarrollar un sistema portable de sensado multimodal inteligente que facilite la recolección de datos para estudiar las diferencias en comportamientos visuales entre conductores adultos jóvenes y adultos mayores, así como la correlación de dichos comportamientos con la aptitud para conducir.”).

8.1 Contribuciones

Las aportaciones de esta tesis se resumen a continuación:

- Implementación de un sistema de recolección de datos portátil que facilita la codificación de datos y es flexible para ajustarse a los requerimientos de estudios de conducción. El sistema propuesto en esta tesis permitió estudiar comportamientos de conducción sin recurrir a codificaciones manuales. Su arquitectura puede ser modificada para ajustarse a las necesidades de recolección de datos de otros estudios (e.g. modificar la tasa de muestreo o cantidad de PAV), o aplicarse en otros contextos (e.g. simuladores de manejo).
- Resultados que dan evidencia de las diferencias de los comportamientos visuales entre adultos mayores y adultos jóvenes, y de cómo estos se ven afectados por diversas variables del contexto de la conducción.
- Tanto el sistema, como los datos recolectados en el estudio, pueden ser utilizados para futuros estudios y como plataforma de enseñanza de temas asociados a la minería de datos. De esto, cabe mencionar que los conjuntos de datos de entrenamiento y comportamientos de datos al conducir, generados a través del sistema de recolección de datos portátil, han sido utilizado previamente por estudiantes de licenciatura para llevar a cabo proyectos que involucran el uso de clasificadores para realizar predicciones. Adicionalmente, los resultados presentados en este trabajo podrían servir de base para llevar a cabo nuevas investigaciones. Por ejemplo, esta plataforma podría utilizarse para

estudiar la aptitud para conducir de adultos mayores con demencia. Otra aplicación útil de este enfoque es en estudios de inatención al conducir vehículos semi-autónomos.

Los resultados obtenidos en esta tesis fueron presentados en diversos eventos de investigación:

- Se presentó el artículo “*A Sensing Architecture Based on Head-Worn Inertial Sensors to Study Drivers’ Visual Patterns*” (Armenta et al., 2019), en el evento “*13th International Conference on Ubiquitous Computing and Ambient Intelligence UCAmI 2019*”. Este trabajo obtuvo el reconocimiento “*Best Short Paper Award*”.
- Elementos de la primera versión del sistema se reportan en artículo de IEEE Access “*Inferring Drivers’ Visual Focus Attention Through Head-Mounted Inertial Sensors*” (Ramirez et al., 2019).
- Resultados preliminares se presentaron como poster en el evento “*Escuela de Otoño sobre Técnicas y Herramientas de Inteligencia Artificial en apoyo a la Investigación sobre Envejecimiento Saludable*”, organizado por el Instituto Politécnico Nacional (IPN), el Instituto Nacional de Geriátría (INGER), el Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE), y el Centro de Investigación Científica y Educación Superior en Ensenada (CICESE), con el apoyo del Consejo Nacional de Ciencia y Tecnología (CONACYT), el cual se celebró en las instalaciones del INAOE en noviembre del 2019.
- Los resultados finales fueron presentados en el evento “*Segundo Seminario Interdisciplinario en Investigación Sobre Envejecimiento 2020*”, organizado por el INGER, y el cual se llevó a cabo de manera virtual en el mes de octubre del 2020. Este trabajo obtuvo reconocimiento como “*Mejor Trabajo*”.

8.2 Limitaciones

Entre las limitaciones de la investigación es preciso mencionar que, si bien los resultados obtenidos durante los estudios concluyeron que existen diferencias significativas en los comportamientos visuales entre grupos de edad, tales resultados no son generalizables a otros grupos de edad. El tamaño de la población es pequeño, por lo que existe la posibilidad de que al incluir más participantes hubiera permitido identificar o

acentuar las correlaciones entre los comportamientos visuales y los resultados de las pruebas cognitivas. A su vez, no se tomó en cuenta la experiencia de manejo de los sujetos o su género como variables que pudieran ayudar a comprender las razones de algunas de las diferencias de sus comportamientos visuales durante la conducción.

8.3 Trabajo Futuro

La relación entre comportamientos visuales y el resultado de los instrumentos en la batería de pruebas cognitivas podría utilizarse para generar funciones de regresión para predecir el estado actual de conductor en algunos de sus dominios cognitivos con base en la duración de la mirada y cantidad de veces que se observa a los PAV.

Otras líneas de investigación surgen en el estudio sobre patrones en el comportamiento visual, donde se analice, por ejemplo, si existe una secuencia sobre los PAV observados que pueda ser generalizada como característica de cada grupo de edad; así como estudiar como afectan otras condiciones contextuales a los comportamientos visuales, tal como las condiciones de tráfico y el cansancio de los conductores.

El sistema de recolección de datos portátil podría ser utilizado para comparar los comportamientos de conducción entre adultos mayores con buena salud mental y adultos mayores con indicios de demencia y/o declive en otros dominios cognitivos para estudiar la posible existencia de diferencias en sus comportamientos de manejo, lo cual incluye sus patrones de atención visual.

A su vez, futuros estudios podrían incluir otros grupos de edad, como adultos en los rangos de los 30 – 44 y 45 – 59 años, con el objetivo de analizar el impacto de la edad en la distribución de su atención a los diferentes PAV en cabina.

Finalmente, el creciente interés en vehículos autónomos deja abierta la pregunta de cuales tareas secundarias deberían ser permitidas al piloto del vehículo. Los resultados presentados en esta tesis, podrían servir para desarrollar sistemas de asistencia en el vehículo que detecten la distracción del conductor con base a su atención visual, para así, generar oportunamente alertas que faciliten que el conductor tome el control del vehículo en situaciones de riesgo.

Referencias

- ¿Qué es el envejecimiento saludable?* (n.d.). Retrieved October 12, 2020, from https://www.who.int/docs/default-source/documents/decade-of-health-ageing/decade-healthy-ageing-update1-es.pdf?sfvrsn=d9c40733_0
- 3-Space™ Mini Bluetooth LE Inertial Motion Sensor - Yost Labs.* (n.d.). Retrieved February 25, 2020, from <https://yostlabs.com/product/bluetooth-mini/>
- Akoglu, H. (2018). User's guide to correlation coefficients. *Turkish Journal of Emergency Medicine, 18*(3), 91–93. <https://doi.org/10.1016/j.tjem.2018.08.001>
- All About the Eye Chart - American Academy of Ophthalmology.* (n.d.). Retrieved June 2, 2020, from <https://www.aao.org/eye-health/tips-prevention/eye-chart-facts-history>
- Altman, N. S. (1992). An Introduction to Kernel and Nearest-Neighbor Nonparametric Regression. *The American Statistician, 46*(3), 175–185. <https://doi.org/10.1080/00031305.1992.10475879>
- Andrews, E. C., & Westerman, S. J. (2012). Age differences in simulated driving performance: Compensatory processes. *Accident Analysis and Prevention, 45*(3), 660–668. <https://doi.org/10.1016/j.aap.2011.09.047>
- Android Studio and SDK tools.* (n.d.). Retrieved February 25, 2020, from <https://developer.android.com/studio>
- Anstey, K. J., Hofer, S. M., & Luszcz, M. A. (2003). Cross-sectional and longitudinal patterns of dedifferentiation in late-life cognitive and sensory function: The effects of age, ability, attrition, and occasion of measurement. *Journal of Experimental Psychology: General, 132*(3), 470–487. <https://doi.org/10.1037/0096-3445.132.3.470>
- Anstey, K. J., Wood, J., LORD, S., & WALKER, J. G. (2005). Cognitive, sensory and

- physical factors enabling driving safety in older adults. *Clinical Psychology Review*, 25(1), 45–65. <https://doi.org/10.1016/j.cpr.2004.07.008>
- Armenta, Rodríguez, & Andrade. (2019). A Sensing Architecture Based on Head-Worn Inertial Sensors to Study Drivers' Visual Patterns. *Proceedings*, 31(1), 34. <https://doi.org/10.3390/proceedings2019031034>
- Asimakopulos, J., Boychuck, Z., Sondergaard, D., Poulin, V., Ménard, I., & Korner-Bitensky, N. (2012). Assessing executive function in relation to fitness to drive: A review of tools and their ability to predict safe driving. *Australian Occupational Therapy Journal*, 59(6), 402–427. <https://doi.org/10.1111/j.1440-1630.2011.00963.x>
- Ball, K K, Clay, O. J., Wadley, V. G., & Roth, D. L. (2005). Predicting driving performance in older adults with the useful field of view test: a meta-analysis. *Proceedings of the Third International Driving Symposium on Human Factors in Driver Assessment, Training, and Vehicle Design; Driving Assessment 2005*, 51–57.
- Ball, Karlene K., Beard, B. L., Roenker, D. L., Miller, R. L., & Griggs, D. S. (1988). Age and visual search: expanding the useful field of view. *Journal of the Optical Society of America A*, 5(12), 2210. <https://doi.org/10.1364/josaa.5.002210>
- Ball, Karlene K. (1997). Enhancing mobility in the elderly: Attentional interventions for driving. *Assessment and Intervention Issues across the Life Span.*, 267–292. <http://ovidsp.ovid.com/ovidweb.cgi?T=JS&PAGE=reference&D=psyc3&NEWS=N&AN=1997-08881-010>
- Bärgman, J., Lisovskaja, V., Victor, T., Flannagan, C., & Dozza, M. (2015). How does glance behavior influence crash and injury risk? A ‘what-if’ counterfactual simulation using crashes and near-crashes from SHRP2. *Transportation Research Part F: Traffic Psychology and Behaviour*, 35, 152–169. <https://doi.org/10.1016/j.trf.2015.10.011>
- Bennett, J. M., Chekaluk, E., & Batchelor, J. (2016). Cognitive Tests and Determining Fitness to Drive in Dementia: A Systematic Review. *Journal of the American Geriatrics Society*, 64(9), 1904–1917. <https://doi.org/10.1111/jgs.14180>
- Brouwer, W. H., Waterink, W., Van Wolfelaar, P. C., & Rothengatter, T. (1991). Divided

- attention in experienced young and older drivers: Lane tracking and visual analysis in a dynamic driving simulator. *Human Factors*, 33(5), 573–582. <https://doi.org/10.1177/001872089103300508>
- Carr, D. B., Barco, P. P., Wallendorf, M. J., Snellgrove, C. A., & Ott, B. R. (2011). Predicting Road Test Performance in Drivers with Dementia. *Journal of the American Geriatrics Society*, 59(11), 2112–2117. <https://doi.org/10.1111/j.1532-5415.2011.03657.x>
- Chapter 3: Functional Classification - Flexibility - Publications - Environment - FHWA.* (n.d.). Retrieved February 25, 2020, from <https://www.fhwa.dot.gov/environment/publications/flexibility/ch03.cfm>
- Choi, H., Kasko, J., & Feng, J. (2019). An Attention Assessment for Informing Older Drivers' Crash Risks in Various Hazardous Situations. *The Gerontologist*, 59(1), 112–123. <https://doi.org/10.1093/geront/gny079>
- Chou, W. Y., Yang, C. H., Tasi, H. C., Lin, Y. C., Chuang, C. F., & Chen, K. H. (2014). Driver distraction recognition based on dual compass motion sensing. *2014 17th IEEE International Conference on Intelligent Transportation Systems, ITSC 2014*, 1375–1380. <https://doi.org/10.1109/ITSC.2014.6957879>
- Chuang, C.-F., Yang, C.-H., & Lin, Y.-H. (2015). HMM-based driving behavior recognition for in-car control service. *2015 IEEE International Conference on Consumer Electronics - Taiwan*, 258–259. <https://doi.org/10.1109/ICCE-TW.2015.7216886>
- Clay, O. J., Wadley, V. G., Edwards, J. D., Roth, D. L., Roenker, D. L., & Ball, K. K. (2005). Cumulative meta-analysis of the relationship between useful field of view and driving performance in older adults: Current and future implications. *Optometry and Vision Science*, 82(8), 724–731. <https://doi.org/10.1097/01.opx.0000175009.08626.65>
- Cloud Storage | Firebase.* (n.d.). Retrieved February 25, 2020, from <https://firebase.google.com/docs/storage>
- Collet, C., Guillot, A., & Petit, C. (2010). Phoning while driving II: a review of driving

- conditions influence. *Ergonomics*, 53(5), 602–616.
<https://doi.org/10.1080/00140131003769092>
- De Raedt, R., & Ponjaert-Kristoffersen, I. (2001). Short Cognitive/Neuropsychological Test Battery for First-Tier Fitness-To-Drive Assessment of Older Adults. *The Clinical Neuropsychologist (Neuropsychology, Development and Cognition: Section D)*, 15(3), 329–336. <https://doi.org/10.1076/clin.15.3.329.10277>
- Diamond, A. (2013). Executive Functions. *Annual Review of Psychology*, 64(1), 135–168. <https://doi.org/10.1146/annurev-psych-113011-143750>
- Dickerson, A. E., Meuel, D. B., Ridenour, C. D., & Cooper, K. (2014). Assessment tools predicting fitness to drive in older adults: A systematic review. *American Journal of Occupational Therapy*, 68(6), 670–680. <https://doi.org/10.5014/ajot.2014.011833>
- Diebel, J. (2006). Representing attitude: Euler angles, unit quaternions, and rotation vectors. *Matrix*, 58, 1–35. <https://doi.org/10.1093/jxb/erm298>
- Face Detection | Firebase*. (n.d.). Retrieved February 25, 2020, from <https://firebase.google.com/docs/ml-kit/detect-faces>
- Ferdinand, A. O., & Menachemi, N. (2014). Associations between driving performance and engaging in secondary tasks: A systematic review. *American Journal of Public Health*, 104(3), 39–48. <https://doi.org/10.2105/AJPH.2013.301750>
- Freund, B., Gravenstein, S., Ferris, R., & Shaheen, E. (2002). Evaluating Driving Performance of Cognitively Impaired and Healthy Older Adults: A Pilot Study Comparing On-Road Testing and Driving Simulation. *Journal of the American Geriatrics Society*, 50(7), 1309–1310. <https://doi.org/10.1046/j.1532-5415.2002.50325.x>
- Friedland, H., Snyckerski, S., Palmer, E. M., & Laraway, S. (2017). The effectiveness of glare-reducing glasses on simulated nighttime driving performance in younger and older adults. *Cognition, Technology and Work*, 19(4), 571–586. <https://doi.org/10.1007/s10111-017-0442-2>
- Fu, W. T., Gasper, J., & Kim, S. W. (2013). Effects of an in-car augmented reality system

on improving safety of younger and older drivers. *2013 IEEE International Symposium on Mixed and Augmented Reality, ISMAR 2013*, 59–66. <https://doi.org/10.1109/ISMAR.2013.6671764>

Google Glass. (n.d.).

Google Sheets. (n.d.). Retrieved February 25, 2020, from <https://www.google.com/sheets/about/>

Hopewell, C. A. (2002). Driving Assessment Issues for Practicing Clinicians. *Journal of Head Trauma Rehabilitation*, *17*(1), 48–61. <https://doi.org/10.1097/00001199-200202000-00007>

Jaeger, J. (2018). Digit Symbol Substitution Test. *Journal of Clinical Psychopharmacology*, *38*(5), 513–519. <https://doi.org/10.1097/JCP.0000000000000941>

Klauer, S. G., Guo, F., Simons-Morton, B. G., Ouimet, M. C., Lee, S. E., & Dingus, T. A. (2014). Distracted Driving and Risk of Road Crashes among Novice and Experienced Drivers. *New England Journal of Medicine*, *307*(1), 54–59. <https://doi.org/10.1056/NEJMsa1204142>

Kok, M., Hol, J. D., & Schön, T. B. (2017). Using Inertial Sensors for Position and Orientation Estimation. *Foundations and Trends® in Signal Processing*, *11*(1–2), 1–153. <https://doi.org/10.1561/20000000094>

Lee, H. C., Cameron, D., & Lee, A. H. (2003). Assessing the driving performance of older adult drivers: On-road versus simulated driving. *Accident Analysis and Prevention*, *35*(5), 797–803. [https://doi.org/10.1016/S0001-4575\(02\)00083-0](https://doi.org/10.1016/S0001-4575(02)00083-0)

Locations and Sensors. (n.d.). Retrieved May 12, 2020, from <https://developers.google.com/glass/develop/gdk/location-sensors>

Lowden, A., Anund, A., Kecklund, G., Peters, B., & Åkerstedt, T. (2009). Wakefulness in young and elderly subjects driving at night in a car simulator. *Accident Analysis and Prevention*, *41*(5), 1001–1007. <https://doi.org/10.1016/j.aap.2009.05.014>

- Mathias, J. L., & Lucas, L. K. (2009). Cognitive predictors of unsafe driving in older drivers: a meta-analysis. *International Psychogeriatrics*, *21*(04), 637. <https://doi.org/10.1017/S1041610209009119>
- Mendeley Desktop*. (n.d.). Retrieved February 25, 2020, from <https://www.mendeley.com/download-desktop/>
- Mendeley Web Importer*. (n.d.). Retrieved February 25, 2020, from <https://www.mendeley.com/reference-management/web-importer>
- ML Kit for Firebase*. (n.d.). Retrieved February 25, 2020, from <https://firebase.google.com/docs/ml-kit>
- Moher, D., Liberati, A., Tetzlaff, J., & Altman, D. G. (2009). Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement. *PLoS Medicine*, *6*(7), e1000097. <https://doi.org/10.1371/journal.pmed.1000097>
- Murphy-Chutorian, E., & Trivedi, M. M. (2010). Head Pose Estimation and Augmented Reality Tracking: An Integrated System and Evaluation for Monitoring Driver Awareness. *IEEE Transactions on Intelligent Transportation Systems*, *11*(2), 300–311. <https://doi.org/10.1109/TITS.2010.2044241>
- Oviedo-Trespalacios, O., Haque, M. M., King, M., & Washington, S. (2016). Understanding the impacts of mobile phone distraction on driving performance: A systematic review. *Transportation Research Part C: Emerging Technologies*, *72*, 360–380. <https://doi.org/10.1016/j.trc.2016.10.006>
- Owsley, C. (2013). Visual processing speed. *Vision Research*, *90*, 52–56. <https://doi.org/10.1016/j.visres.2012.11.014>
- Pangman, V. C., Sloan, J., & Guse, L. (2000). An examination of psychometric properties of the Mini-Mental State Examination and the Standardized Mini-Mental State Examination: Implications for clinical practice. *Applied Nursing Research*, *13*(4), 209–213. <https://doi.org/10.1053/apnr.2000.9231>
- Piersma, D., Fuermaier, A. B. M., de Waard, D., Davidse, R. J., de Groot, J., Doumen, M. J. A., Bredewoud, R. A., Claesen, R., Lemstra, A. W., Vermeeren, A., Ponds, R.,

- Verhey, F., Brouwer, W. H., & Tucha, O. (2016). Prediction of Fitness to Drive in Patients with Alzheimer's Dementia. *PLOS ONE*, *11*(2), e0149566. <https://doi.org/10.1371/journal.pone.0149566>
- Ploetz, T., & Healey, J. (2018). ISWC 2017: Riding the Waves of Wearables. *IEEE Pervasive Computing*, *17*(2), 78–83. <https://doi.org/10.1109/MPRV.2018.022511248>
- Ponds, R. W. H. M., Brouwer, W. H., & Van Wolffelaar, P. C. (1988). Age Differences in Divided Attention in a Simulated Driving Task. *Journal of Gerontology*, *43*(6), P151–P156. <https://doi.org/10.1093/geronj/43.6.P151>
- Position sensors | Android Developers*. (n.d.). Retrieved June 3, 2020, from https://developer.android.com/guide/topics/sensors/sensors_position
- Ramirez, J. M., Rodriguez, M. D., Andrade, A. G., Castro, L. A., Beltran, J., & Armenta, J. S. (2019). Inferring Drivers' Visual Focus Attention Through Head-Mounted Inertial Sensors. *IEEE Access*, *7*, 185422–185432. <https://doi.org/10.1109/ACCESS.2019.2960567>
- Reitan, R. M. (1958). Validity of the Trail Making Test as an Indicator of Organic Brain Damage. *Perceptual and Motor Skills*, *8*(3), 271–276. <https://doi.org/10.2466/pms.1958.8.3.271>
- Salthouse, T. A. (1991). Mediation of adult age differences in cognition by reductions in working memory and speed of processing. *Psychological Science*, *2*(3), 179–183. <https://doi.org/10.1021/nn405488n>
- Salthouse, T. A. (2005). Relations between cognitive abilities and measures of executive functioning. *Neuropsychology*, *19*(4), 532–545. <https://doi.org/10.1037/0894-4105.19.4.532>
- Segawa, M., Okada, M., Renge, K., Tada, M., Noma, H., & Utsumi, A. (2014). Elderly driver retraining using automatic evaluation system of safe driving skill. *IET Intelligent Transport Systems*, *8*(3), 266–272. <https://doi.org/10.1049/iet-its.2013.0027>
- Social Science Statistics*. (n.d.). Retrieved February 25, 2020, from <https://www.socscistatistics.com/>

- Tamura, T. (2014). Wearable Inertial Sensors and Their Applications. In *Wearable Sensors: Fundamentals, Implementation and Applications*. Elsevier. <https://doi.org/10.1016/C2013-0-06896-X>
- Timothy A. Salthouse. (1996). The Processing-Speed Theory of Adult Age Differences in Cognition. *Psychological Review*, 103(3), 403–428.
- Urlings, J. H. J., Cuenen, A., Brijs, T., Lutin, M., & Jongen, E. M. M. (2017). Aiding medical professionals in fitness-to-drive screenings for elderly drivers: development of an office-based screening tool. *International Psychogeriatrics*, 30(8), 1–15. <https://doi.org/10.1017/S1041610217002678>
- Wechsler, K., Drescher, U., Janouch, C., Haeger, M., Voelcker-Rehage, C., & Bock, O. (2018). Multitasking During Simulated Car Driving: A Comparison of Young and Older Persons. *Frontiers in Psychology*, 9. <https://doi.org/10.3389/fpsyg.2018.00910>
- Weka 3 - Data Mining with Open Source Machine Learning Software in Java*. (n.d.). Retrieved February 28, 2020, from <https://www.cs.waikato.ac.nz/ml/weka/>
- Wikman, A. S., & Summala, H. (2005). Aging and time-sharing in highway driving. *Optometry and Vision Science*, 82(8), 716–723. <https://doi.org/10.1097/01.opx.0000174721.33377.b8>
- Yang, J. H., & Jeong, H. Bin. (2015). Validity Analysis of Vehicle and Physiological Data for Detecting Driver Drowsiness, Distraction, and Workload. *2015 IEEE International Conference on Systems, Man, and Cybernetics*, 1238–1243. <https://doi.org/10.1109/SMC.2015.221>

Apéndice A. Formato de consentimiento informado



Consentimiento Informado

A través del presente documento, Yo _____ acepto participar en la investigación titulada: ***“Sistema de sensado multimodal inteligente para estudiar los comportamientos visuales al conducir”***.

Habiendo sido informado del propósito de la misma, así como de los objetivos y teniendo la confianza plena de que la información que se vierte en el instrumento será sólo y exclusivamente para fines de la investigación, además confío en que el investigador utilizará adecuadamente dicha información asegurándome la máxima confidencialidad. Para lograr lo anterior, estoy de acuerdo en realizar una batería de instrumentos que evalúan mi estado cognitivo, así como realizar un recorrido en mi vehículo para dar a conocer mis comportamientos visuales mientras conduzco, en el cual será grabado a través de una cámara de video.

A T E N T A M E N T E

SUJETO DE PRUEBA

COMPROMISO DE CONFIDENCIALIDAD

El investigador del estudio para el cual Usted ha manifestado su deseo de participar, habiendo dado su consentimiento informado, se compromete con usted a guardar la máxima confidencialidad de la información, así como también le asegura que los hallazgos serán utilizados solo con fines de investigación y no le perjudicarán en lo absoluto.

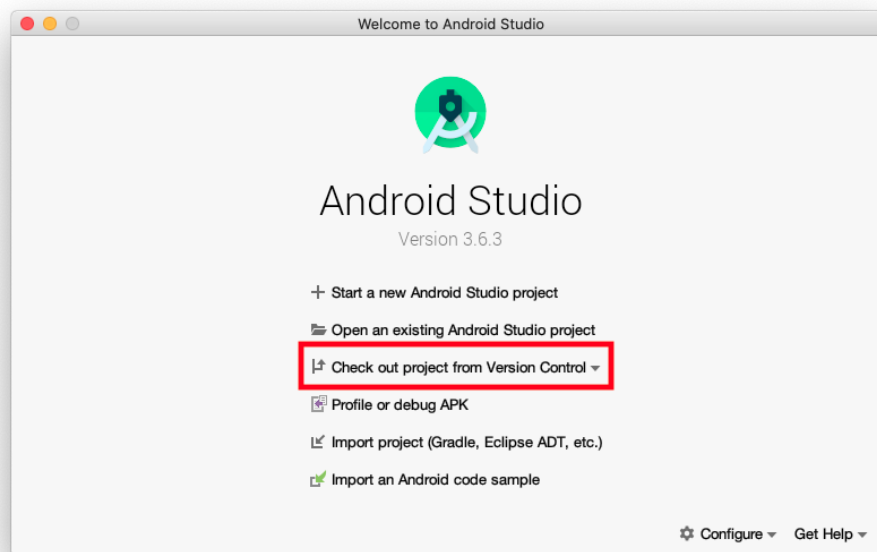
A T E N T A M E N T E

ING. JOSUÉ SAÚL ARMENTA ESPINOZA
INVESTIGADOR


Apéndice 2. Descarga, compilación y configuración de ARF

El código fuente de la aplicación se encuentra en el repositorio <https://github.com/josue-armenta/ARF.git>, el cual es utilizado por el IDE *Android Studio* (*Android Studio and SDK Tools*, n.d.) para desplegar directamente la aplicación en un teléfono o tableta con sistema operativo Android, el cual debe haber sido previamente habilitado para ejecutar aplicaciones en modo *debug*. El procedimiento para desplegar y configurar la aplicación se explica a continuación.


Al ejecutar el IDE *Android Studio*, se mostrará la ventana de bienvenida. Desde ahí se debe elegir la opción *Check out Project from Version Control*, y después elegir la opción *Git*.



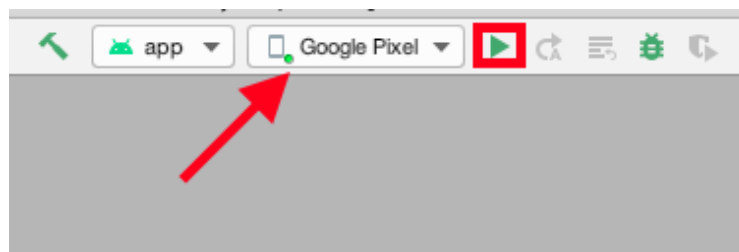
En el siguiente dialogo, deberá escribirse la URL del repositorio en el campo *URL* y posteriormente presionar el botón *Clone*.



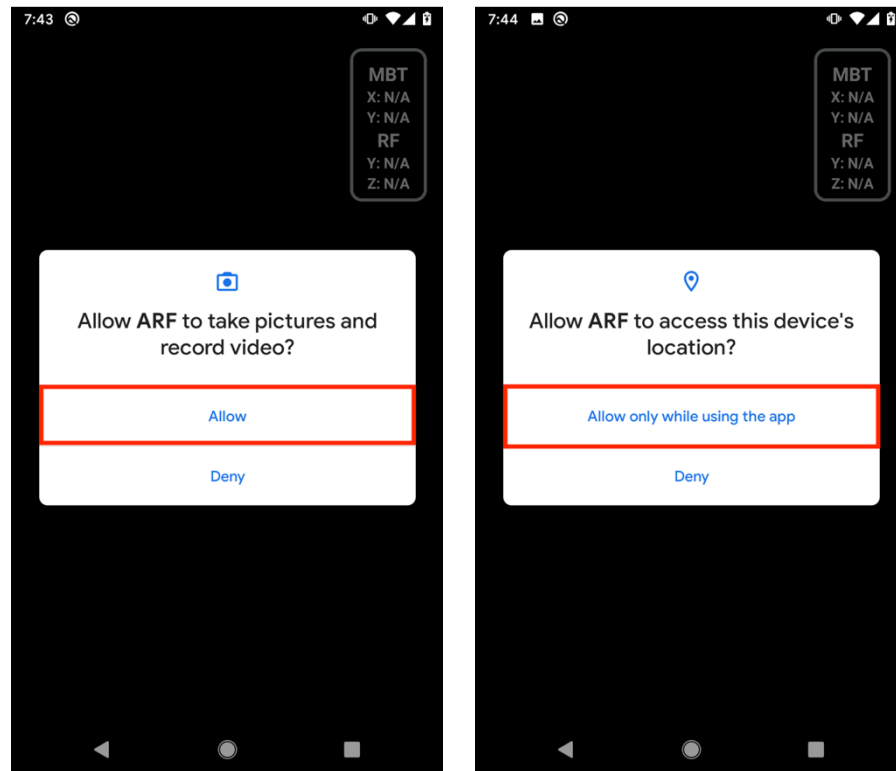
Una vez descargado el código fuente, se le preguntará al usuario si desea abrir el proyecto, a lo cual se deberá responder de manera afirmativa mediante el botón *Yes*.



Una vez abierto el proyecto, y con el dispositivo conectado al equipo de computo mediante USB, se verifica que este se encuentre seleccionado y se presiona la combinación de botones *Ctrl + R* para desplegar la aplicación en el teléfono o tableta. Lo anterior hará que ARF se ejecute automáticamente al ser desplegada.



Una vez ejecutada, la aplicación solicitará inmediatamente que se le otorguen los permisos necesarios para su correcto funcionamiento.



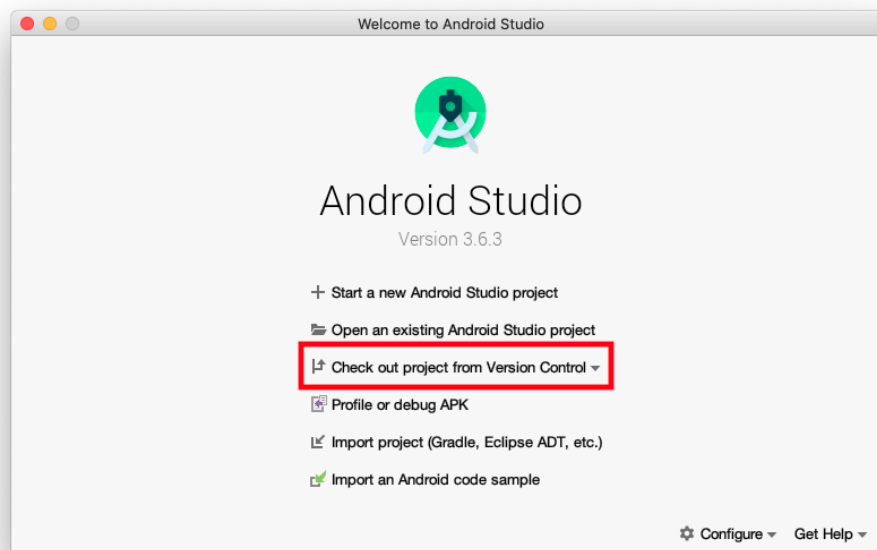
La aplicación utilizará la cámara del dispositivo para estimar la orientación de la cabeza mediante ángulos de Euler, datos que transmitirá mediante el protocolo *Bluetooth* cuando *ARMID* se lo solicite.

Apéndice 3. Descarga, compilación y configuración de ARMID


El código fuente de la aplicación se encuentra en el repositorio <https://github.com/josue-armenta/ARMID.git>, el cual es utilizado por el IDE *Android Studio* (*Android Studio and SDK Tools*, n.d.) para desplegar directamente la aplicación en un teléfono o tableta con sistema operativo Android, el cual debe haber sido previamente habilitado para ejecutar aplicaciones en modo *debug*.

Para utilizar las funciones de recolección de datos de entrenamiento y comportamiento durante la conducción, es necesario contar con un dispositivo 3-Space Mini Bluetooth, el cual debió ser previamente enlazado al teléfono o tableta que ejecutará ARMID, así como otro dispositivo Android que ejecute el componente ARF, también previamente enlazado mediante el protocolo *Bluetooth*. El procedimiento para desplegar y configurar la aplicación se explica a continuación.


Al ejecutar el IDE *Android Studio*, se mostrará la ventana de bienvenida. Desde ahí se debe elegir la opción *Check out Project from Version Control*, y después elegir la opción *Git*.




En el siguiente dialogo, deberá escribirse la URL del repositorio en el campo *URL* y posteriormente presionar el botón *Clone*.




Una vez descargado el código fuente, se le preguntará al usuario si desea abrir el proyecto, a lo cual se deberá responder de manera afirmativa mediante el botón *Yes*.



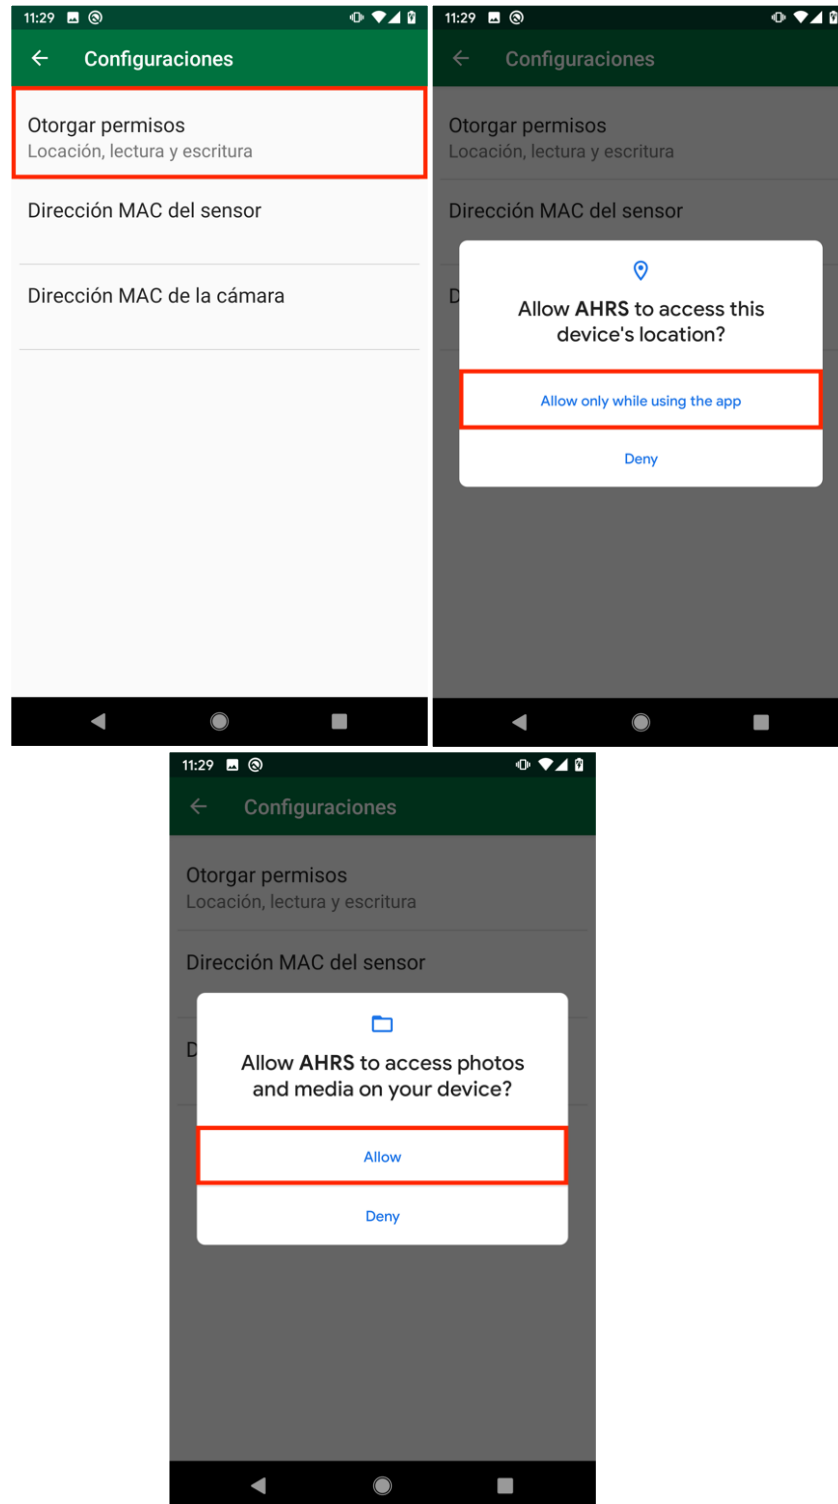
Una vez abierto el proyecto, y con el dispositivo conectado al equipo de computo mediante USB, se verifica que este se encuentre seleccionado y se presiona la combinación de botones *Ctrl + R* para desplegar la aplicación en el teléfono o tableta, lo cual hará que ARMID se ejecute automáticamente en el dispositivo



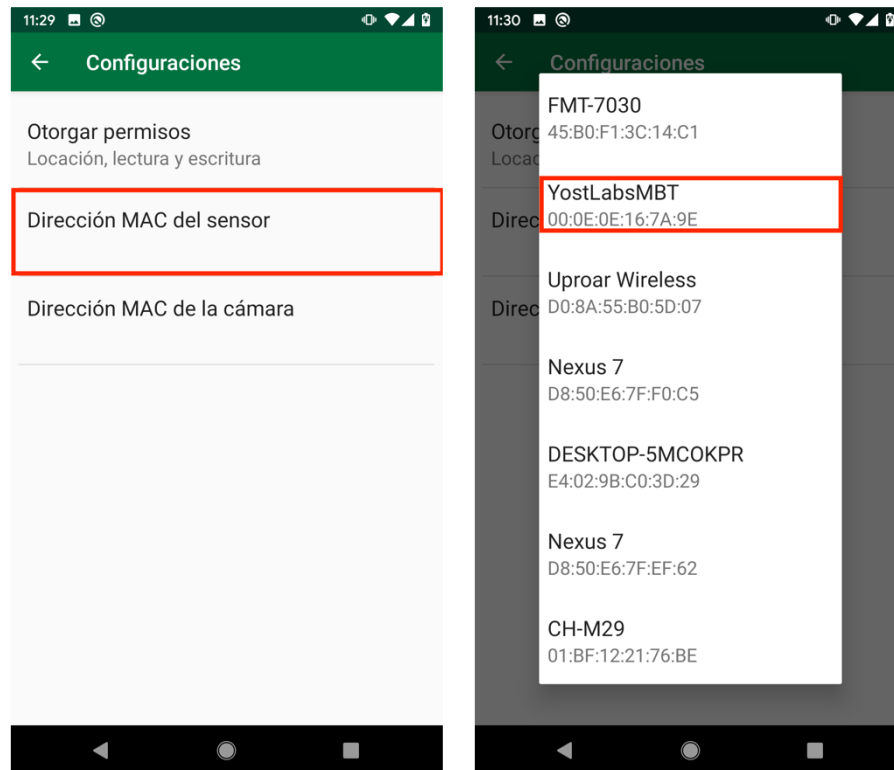
Con la aplicación corriendo, se presiona el botón de la esquina superior izquierda



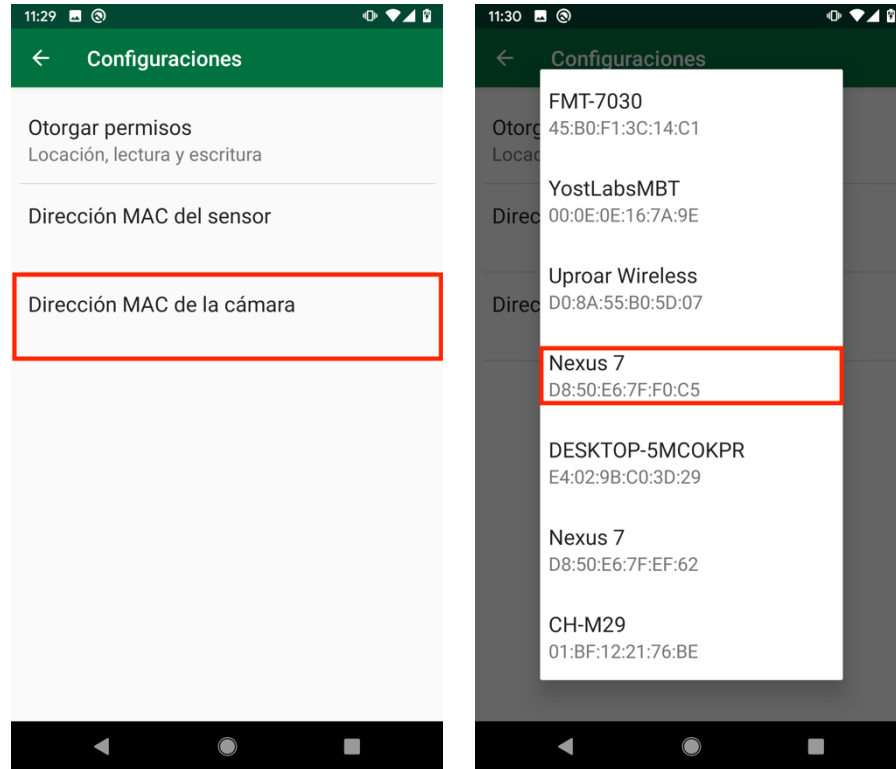
En la siguiente pantalla, debe escogerse la opción *Otorgar permisos*, con la cual se solicitará acceso al sensor GPS y la lectura/escritura de archivos en el dispositivo, ambos necesarios para el correcto funcionamiento del componente.



Una vez otorgados los permisos, se procede con la opción *Dirección MAC del sensor*, lo cual le permitirá al componente comunicarse con el componente AHRS. A continuación, debe seleccionarse la dirección MAC del dispositivo, la cual viene acompañada del nombre del sensor para facilitar su ubicación en la lista.



Este procedimiento deberá repetirse con la opción *Dirección MAC de la cámara*, donde deberá especificarse la dirección MAC del dispositivo que contiene el componente ARF.



Con los permisos otorgados y los sensores encendidos y enlazados, el componente se encuentra listo para realizar recolecciones de datos.