

Universidad Autónoma de Baja California

Facultad de Ingeniería

Maestría y Doctorado en Ciencias e Ingeniería



“Inferencia del enfoque visual de conductores a través de sensores inerciales montados en la cabeza”

TESIS

Que presenta para obtener el grado de DOCTOR EN CIENCIAS

JOSÉ MANUEL RAMÍREZ ZARATE

DIRECTOR DE TESIS:

DRA. MARCELA DEYANIRA RODRÍGUEZ URREA

CO-DIRECTOR DE TESIS:

DR. ÁNGEL GABRIEL ANDRADE REÁTIGA

Universidad Autónoma de Baja California

Facultad de Ingeniería

Inferencia del enfoque visual de conductores a través de sensores inerciales montados en la cabeza

TESIS

que para cubrir parcialmente los requisitos necesarios para obtener el grado de

DOCTOR EN CIENCIAS

Presenta

José Manuel Ramírez Zarate

Aprobada por:

Dr. Marcela Deyanira Rodríguez Urrea
Director de Tesis

Dra. Ángel Gabriel Andrade Reátiga
Co-director de Tesis

Dr. Luis Adrián Castro Quiroa
Miembro del Comité

Dr. Guillermo Galaviz Yáñez
Miembro del Comité

Dr. Juan Pablo García Vázquez
Miembro del Comité

Mexicali Baja California, México. Junio de 2021

Resumen

La distracción durante la conducción son una de las principales causas de accidentes. La mayoría de los métodos para inferir distracciones durante la conducción son sistemas basados en la detección de la orientación de la cabeza mediante la visión, uno de los desafíos importantes de este enfoque es desarrollar algoritmos robustos que detecten rasgos faciales y oculares bajo diversas condiciones de iluminación.

Este trabajo de investigación se basa en inferir el lugar de la cabina del vehículo a la que el conductor centra su atención utilizando sensores inerciales montados en la cabeza. Para lograr este objetivo, se utilizó un dispositivo que incluía un acelerómetro, giroscopio y magnetómetro para recopilar datos de diez participantes que condujeron en condiciones semi-naturalistas. Se generaron clasificadores mediante el uso de las técnicas de aprendizaje automático: Support Vector Machine (SVM lineal y RBF), k vecino cercano (k-NN) y Random Forest (RF). Estas técnicas, excepto SVM lineal, produjeron una exactitud, precisión y recuerdo superior al 96%

Los resultados obtenidos demuestran que las señales sin procesar recopiladas de los sensores inerciales brindan suficiente información sobre la postura de la cabeza asociada con el lugar de la cabina del automóvil a la cual el conductor centra su atención.

Resumen aprobado por:

Dr. Marcela Deyanira Rodríguez Urrea
Director de Tesis

Dra. Ángel Gabriel Andrade Reátiga
Co-director de Tesis

Abstract

Distraction while driving is one of the leading causes of accidents. Most of the methods for inferring distractions while driving are systems based on the detection of head orientation by vision techniques. One of the major challenges of this approach is developing robust algorithms that detect facial and ocular features under various conditions of lighting.

This research work is based on inferring the location in the vehicle cabin to which drivers focus their attention using head-mounted inertial sensors. To achieve this goal, accelerometer, gyroscope, and magnetometer data were collected from ten participants who drove under semi-naturalistic conditions. The data was used to train classifiers using machine learning techniques such as: Support Vector Machine (linear SVM and RBF), k Nearest Neighbor (k-NN) and Random Forest (RF). These techniques, except linear SVM, produced an accuracy, precision, and recall greater than 96%.

The results obtained demonstrate that the raw signals collected from the inertial sensors provide sufficient information on the head posture associated with the location in the car cabin to which the driver focuses his attention.

Abstract approved by:

Dr. Marcela Deyanira Rodríguez Urrea
Thesis Advisor

Dra. Ángel Gabriel Andrade Reátiga
Thesis Co-advisor

Dedicatoria

Agradecimientos

Índice general.

RESUMEN	IV
ABSTRACT	V
DEDICATORIA	VI
AGRADECIMIENTOS	VII
ÍNDICE GENERAL.	VIII
ÍNDICE DE FIGURAS	XI
ÍNDICE DE TABLAS	XIII
CAPÍTULO 1	14
1. INTRODUCCIÓN	14
1.1 CONTEXTO DEL PROBLEMA	14
1.2 ENFOQUE PROPUESTO	15
1.3 PREGUNTAS DE INVESTIGACIÓN	18
1.4 OBJETIVO DE LA TESIS	18
1.4.1 OBJETIVO GENERAL	18
1.4.2 OBJETIVOS ESPECÍFICOS	19
CAPÍTULO 2	21
2. ANTECEDENTES	21
2.1 FUNDAMENTOS TEÓRICOS	21
2.1.1 SENSORES INERCIALES	21
2.1.2 ALGORITMOS DE CLASIFICACIÓN Y PARÁMETROS DE CONFIGURACIÓN	24
2.1.3 TÉCNICAS DE ENTRENAMIENTO DE MÁQUINAS DE APRENDIZAJE	26
2.1.4 MÉTRICAS DE DESEMPEÑO	27
2.2 TRABAJO RELACIONADO	28

2.2.1	MÉTODO	28
2.2.2	RESULTADOS	30
CAPÍTULO 3		36
3. ESTUDIOS PREVIOS DE FACTIBILIDAD DE LOS SENSORES		36
3.1 IMPACTO DE LAS TÉCNICAS DE ENTRENAMIENTO DE MÁQUINAS DE APRENDIZAJE EN LA INFERENCIA DEL FOCO DE ATENCIÓN		36
3.1.1	MÉTODO	36
3.1.2	RESULTADOS	40
3.2 IMPACTO DE LA VELOCIDAD Y ORIENTACIÓN DEL AUTOMÓVIL EN LA INFERENCIA DEL FOCO DE ATENCIÓN		41
3.2.1	MÉTODO	41
3.2.2	RESULTADOS	42
3.3 DISCUSIÓN		44
CAPÍTULO 4		45
4. MÉTODO PARA DETERMINAR LA INFERENCIA DEL FOCO DE ATENCIÓN		45
4.1 PARTICIPANTES		45
4.2 ACTIVIDADES PARA RECOLECTAR DATOS		45
4.3 DESCRIPCIÓN DEL CONJUNTO DE DATOS		46
CAPÍTULO 5		49
5. RESULTADOS		49
5.1 SVM		49
5.2 K-NN		50
5.3 RF		51
5.4 COMPARACIÓN DE LAS MÁQUINAS DE CLASIFICACIÓN		52
CAPÍTULO 6		55
6. CONCLUSIONES		55
6.1 CONTRIBUCIONES		55
6.2 LIMITACIONES DE LOS ESTUDIOS		56
6.3 TRABAJO A FUTURO		57

REFERENCIAS **58**

APÉNDICE A **69**

APÉNDICE B **71**

Índice de figuras

FIGURA 1 ACELERÓMETRO	22
FIGURA 2 MAGNETÓMETRO	22
FIGURA 3 GIROSCOPIO	23
FIGURA 4 ACELERÓMETRO, MAGNETÓMETRO Y GIROSCOPIO.	24
FIGURA 5 DIAGRAMA DE FLUJO DE LA BÚSQUEDA DE ALCANCE	30
FIGURA 6 NÚMERO DE TRABAJOS ENFOCADOS EN DETECTAR CONDUCTAS DE INATENCIÓN (EJE X), MEDIANTE EL USO DE DIFERENTES TÉCNICAS (EJE Y)	31
FIGURA 7 ARTÍCULOS PRESENTADOS POR AÑO EN REVISTA Y EN CONFERENCIAS.	32
FIGURA 8 ENFOQUE DE LOS ESTUDIOS POR AÑO	33
FIGURA 9 TIPOS DE ENFOQUES DE INVESTIGACIÓN	33
FIGURA 10 SENSORES O DISPOSITIVOS UTILIZADOS PARA ABORDAR LA PROBLEMÁTICA	34
FIGURA 11 CABINA DEL VEHÍCULO ETIQUETADA CON LOS SPOTS DESDE EL S0 HASTA EL S10.	37
FIGURA 12 BULEVAR DE CONDUCCIÓN, PARA EVALUAR EL IMPACTO DE LA VELOCIDAD EN LOS DATOS.	38
FIGURA 13 CONDUCTOR PORTANDO EL SOMBRERO DURANTE LA CONDUCCIÓN.	39
FIGURA 14 EJEMPLO DE LAS TUPLAS DE INFORMACIÓN CAPTURADAS DURANTE UNA SESIÓN DE CONDUCCIÓN.	40
FIGURA 15 COMPARACIÓN ENTRE CROSS-VALIDATION Y PERCENT SPLIT.	41
FIGURA 16 VELOCIDADES DE CONDUCCIÓN.	42
FIGURA 17 DIRECCIONES DE CONDUCCIÓN.	43
FIGURA 18 CONDUCCIÓN EN AMBAS DIRECCIONES.	43
FIGURA 19 RUTA SEGUIDA POR LOS PARTICIPANTES DURANTE LAS SESIONES DE CONDUCCIÓN EN EL ESTACIONAMIENTO PRIVADO.	46
FIGURA 20 DATOS CAPTURADOS EN CADA SPOT POR PARTICIPANTE.	48
FIGURA 21 DESEMPEÑO DE LA SVM CON UN KERNEL LINEAL.	50
FIGURA 22 DESEMPEÑO DE LA SVM CON UN KERNEL RBF.	50
FIGURA 23 DESEMPEÑO DE K-NN.	51

FIGURA 24 DESEMPEÑO DE RANDOM FOREST.	52
FIGURA 25 MATRICES DE CONFUSIÓN OBTENIDAS DE CADA CLASIFICADOR.	54
FIGURA 26 SENSORES Y SUS COMBINACIONES.	69
FIGURA 27 PORCENTAJES EVALUADOS CON K-NN.	70
FIGURA 28 PROTOCOLO BASADO EN DIFUSIÓN PARA EL PASO DE MENSAJES UN ESCENARIO QUE DESCRIBE CÓMO SE PROPAGA UN MENSAJE, EL DIAGRAMA DE FLUJO B ILUSTRA LOS PASOS DEL PROTOCOLO.	74
FIGURA 29 DIAGRAMA DE FLUJO.	75
FIGURA 30 RSSI EN INTERIORES.	76
FIGURA 31 RSSI EN EXTERIORES.	76

Índice de tablas

TABLA 1 DATOS RECOLECTADOS.	47
TABLA 2 COMPARACIÓN DE LAS MÉTRICAS DE DESEMPEÑO DE LAS TÉCNICAS DE CLASIFICACIÓN	53

Capítulo 1

1. INTRODUCCIÓN

1.1 CONTEXTO DEL PROBLEMA

La distracción o la inatención durante la conducción de vehículos, se refiere a la falta de atención a las tareas de conducción debido a la participación en otras tareas. Estas otras tareas pueden ser cualquier distracción del tipo cognitiva, física o visual las cuales, conducen a la degradación del rendimiento de la conducción [1].

Una distracción cognitiva es aquella que no permite concentrarse en la tarea de conducción, como por ejemplo, entablar una conversación con los pasajeros o contestar una llamada telefónica, en este caso, el conductor podría estar más atento a la conversación que a la misma conducción. Una distracción física requiere alejar las manos del volante, como cuando se sujeta una hamburguesa, arriesgando el control del vehículo [2]. Por otro lado, las distracciones visuales provoca que el conductor aleje la vista del camino, por ejemplo, cuando circula a 65 millas por hora, el conductor revisa un mapa de localización por dos segundos, para ese entonces se habrá recorrido una distancia de dos terceras partes de un campo de futbol americano antes de regresar la vista al camino, lo suficiente para involucrarse en un accidente serio[2].

Se estima que las diversas distracciones causan el 23% de los accidentes o casi accidentes [3], y que podrían reducirse en un 10-20% mediante sistemas de monitoreo y predicción de los comportamientos de la conducción [4], [5]. Evitar la distracción durante la conducción ha sido de particular interés al utilizar artefactos de navegación [6]. También se han explorado métodos para detectar la distracción del conductor y la somnolencia, estos se basan principalmente en el análisis de las características abstraídas de imágenes y videos de las expresiones faciales, posición de la cabeza [5], y el

comportamiento de la mirada [7]. Se puede decir que, para detectar la mayoría de las distracciones físicas y visuales, detectar la postura de la cabeza del conductor es un indicador apropiado, además de que en las distracciones físicas se realizan movimientos de cualquier otra parte del cuerpo.

En particular, la posición de la cabeza (o la orientación de la cabeza) es un fuerte indicador del campo de visión del conductor y del centro de atención [8], [9]; por lo que se ha considerado como un proceso integral para monitorear el nivel de alerta del conductor [9]. Sin embargo, los métodos que se apoyan en el procesamiento de imágenes para determinar distracciones durante la conducción requieren que la cabina del vehículo sea equipada con cámaras [1], [8], [10]. Por ejemplo, faceLAB utiliza dos cámaras para determinar la posición de la cabeza y la dirección de la mirada del ojo [10]. Por otro lado, los dispositivos ponibles, como los lentes inteligentes, han surgido como una plataforma de investigación alternativa y de productos para una amplia gama de sistemas de apoyo portátiles debido a sus capacidades de detección. La seguridad en relación con el uso de los lentes inteligentes durante la conducción ha sido cuestionada, ya que permiten a los usuarios enviar mensajes de texto o acceder sus redes sociales a través de comandos de voz. Sin embargo, algunas investigaciones han demostrado que estos dispositivos ponibles pueden mejorar la seguridad de los conductores que corren el riesgo de sufrir fatiga (por ejemplo, los conductores de camiones); y que quienes usan teléfonos inteligentes se distraen más y con más frecuencia que quienes utilizan Google Glass [11].

1.2 ENFOQUE PROPUESTO

En los métodos que utilizan cámaras para detectar la inatención del conductor, existe la inquietud de que perturban la privacidad del conductor. Por lo anterior, en [12], proponen el uso de filtros para ocultar su identidad, mientras que las cámaras solo recolectan datos. Además, se requiere adaptar el vehículo para montar las cámaras. Particularmente, los métodos que utilizan cámaras presentan limitaciones para detectar los gestos faciales y oculares en condiciones de poca luz.

Como se muestra en [13] existe un número mínimo de cámaras para poder detectar de forma adecuada la orientación de la cabeza, esto implica realizar la instalación de cámaras dentro de la cabina del vehículo para poder realizar la detección. Sin embargo, el uso de cámaras no solamente implica la instalación de estas dentro del vehículo, sino que además existen otros factores como por ejemplo la iluminación el uso de lentes, barba o algún objeto que interfiera con la detección del rostro de la persona.

Con el crecimiento en el uso de dispositivos portátiles, se crea un nicho de oportunidad de realizar el monitoreo constante de la posición de la cabeza de forma no invasiva; utilizando los sensores inerciales que se encuentran embebidos en estos dispositivos. Estos dispositivos portátiles son los dispositivos preferibles gracias a su facilidad de uso, experiencia del usuario y rendimiento. Al mismo tiempo, estos dispositivos presentan limitaciones en términos de capacidad de cómputo y memoria, lo que obliga a diseñar algoritmos eficientes y simples [12].

El reconocimiento de las posturas y actividades del usuario durante la conducción son particularmente importantes, ya que permiten a las aplicaciones de los dispositivos portátiles, personalizar sus operaciones de acuerdo con la situación actual de sus usuarios [14].

En el presente trabajo se utilizaron sensores inerciales embebidos en dispositivos portátiles en la cabeza, evitando instrumentar los vehículos con múltiples cámaras de video para realizar grabaciones de la conducción. Es por esto que, para monitorear a los conductores de una forma no intrusiva, se propuso utilizar sensores inerciales empotrados en dispositivos de uso diario como lo podían ser los lentes inteligentes. Además, se espera que al igual como sucedió con los teléfonos celulares que en un principio el porcentaje de las personas que lo utilizaban era muy bajo y en poco tiempo tuvo un incremento muy acelerado, se espera que la utilización de los dispositivos vestibles se incremente rápidamente gracias a la madurez de tecnologías como el internet de las cosas o las nuevas generaciones de telefonía celular.

Esta tesis propone y explora el uso de sensores inerciales, para inferir el foco de atención actual de los conductores a partir de la postura de la cabeza. Diversos trabajos demuestran su potencial no solo para analizar la postura de la cabeza [15], [16], sino también la postura de la muñeca del conductor para detectar el uso y ángulo del volante [17].

Como se explica en [18], tanto las tareas secundarias son riesgosas, como aquellas altamente relacionadas con la conducción que exigen desviar la mirada hacia alguna zona diferente al camino. Existen cuatro tipos de inatención del conductor:

- Distracción por una tarea secundaria, que se refiere a desviar la atención del conductor de la tarea de conducir, por ejemplo, cuando tienen que introducir un CD, alcanzar un objeto en el asiento trasero, configurar la temperatura del vehículo;
- La falta de atención de la carretera debido a que se realiza una tarea que está directamente relacionada con la tarea de conducción, por ejemplo, verificar la velocidad a la que se conduce, verificar los espejos;
- Somnolencia, que incluye cerrar los ojos y realizar bostezos repetidos; y
- Miradas completamente fuera de la carretera, que implica mirar a peatones, voltear a ver las señales de tránsito, leer los nombres de las calles buscando una dirección [19].

En esta tesis se estudian las distracciones por realizar una tarea secundaria y la falta de atención por observar distintos puntos de la cabina del vehículo. Para cumplir con los objetivos de esta investigación se llevó a cabo la siguiente metodología, el desarrollo de dos estudios para realizar la inferencia del foco de atención de los conductores para identificar las zonas de la cabina del vehículo en las que el conductor enfoca su atención durante la conducción. Para la inferencia de las zonas de atención se utilizaron algoritmos de inteligencia artificial que reciben datos crudos obtenidos de sensores inerciales (acelerómetro, magnetómetro y giroscopio) embebidos en dispositivos ponibles en la cabeza. Entre los algoritmos explorados se encuentran Support Vector Machine (SVM), k-

Nearest Neighbor (k-NN) y Random Forest (RF). SVM y RF tienen la característica de ser insensibles al ruido y tienen un buen desempeño con datos no balanceados comparadas con redes neuronales artificiales (ANN) [20]. Además, también se seleccionó k-NN ya que junto con SVM y RF generalmente superan a otros clasificadores supervisados tradicionales en varios contextos de aplicación, como lo puede ser en el reconocimiento de actividades humanas a partir de datos de sensores inerciales embebidos dentro dispositivos portátiles [21] y aplicaciones de imágenes de detección remota [22].

El planteamiento de esta investigación se origina por el poco conocimiento sobre el desempeño de sensores inerciales para detectar la postura de la cabeza de los conductores mientras realizan actividades secundarias durante la conducción. Por lo anterior, se proponen las siguientes preguntas y objetivos de investigación

1.3 PREGUNTAS DE INVESTIGACIÓN

Las preguntas que se abordan en esta tesis son las siguientes:

PI1: ¿Utilizar datos crudos obtenidos de sensores inerciales es suficiente para inferir el foco de atención de los conductores?

PI3: ¿Cuál técnica de inferencia es la más adecuada para inferir el foco de atención del conductor durante la conducción?

1.4 OBJETIVO DE LA TESIS

1.4.1 Objetivo General

Desarrollar un sistema basado en Inteligencia Artificial que permita inferir el foco de atención de conductores a partir del uso de sensores inerciales contenidos dentro de dispositivos portátiles.

1.4.2 Objetivos Específicos

- Identificar cuáles son las técnicas de clasificación más adecuadas para la utilización de datos crudos de sensores inerciales.
- Determinar si la velocidad y la dirección de la conducción tienen algún impacto en las mediciones realizadas por los sensores inerciales.
- Evaluar el desempeño de las técnicas de clasificación para la inferencia del foco de atención del conductor.

Para alcanzar este objetivo, se plantea recolectar los datos crudos de los sensores inerciales, posteriormente estos datos serán utilizados para inferir el foco de atención de los conductores mediante el uso de técnicas de clasificación basadas en aprendizaje supervisado [11], [23].

La estructura de esta tesis se compone de la siguiente información:

- Capítulos 2: Donde se abordarán temas relacionados con el fundamento teórico y trabajo relacionado
- Capítulo 3: Aborda temas sobre estudios previos de factibilidad de los sensores.
- Capítulo 4: Aborda los temas donde se habla de los participantes, actividades realizadas para la recolección de datos y la descripción del conjunto de datos.
- Capítulo 5: En este capítulo se muestran los resultados de la SVM, k-NN, RF y la comparación de estos resultados.
- Capítulo 6: Aborda lo que se realizará como trabajo futuro.

Capítulo 2

2. ANTECEDENTES

2.1 FUNDAMENTOS TEÓRICOS

Con el propósito justificar la utilización de los componentes necesarios para alcanzar el objetivo de este trabajo de investigación, se describe a continuación el funcionamiento de cada uno de los sensores utilizados, así como de los algoritmos de clasificación, técnicas de entrenamiento y las métricas de desempeño a utilizar.

2.1.1 Sensores Inerciales

Un acelerómetro es un sensor capaz de registrar variaciones de aceleración en el tiempo, en términos de $\frac{m}{s^2}$ ó g . El principio general de funcionamiento del acelerómetro se basa en una masa que cuelga en el centro de un cubo y se sujeta a todos los lados del cubo mediante un resorte, pero debido a alguna fuerza externa que mueva al acelerómetro y por consecuencia a la masa, ésta tiende a desplazarse, y por cual el dispositivo mide el movimiento de los resortes, el cual se correlaciona con la magnitud de la fuerza ejercida sobre el acelerómetro (figura 1).

Hoy en día el uso generalizado de los teléfonos inteligentes ha aumentado significativamente y la mayoría de los teléfonos celulares modernos tienen un acelerómetro triaxial incorporado. Además de que la gran mayoría de dispositivos posibles dependen en su funcionamiento de este sensor.




Figura 1 Acelerómetro.

El magnetómetro es un sensor de medición vectorial común utilizado en aeronaves. Se caracteriza por realizar mediciones simultáneas de la dirección y la fuerza del campo magnético, además tiene un amplio rango de resistencia a la temperatura y sin componentes móviles. Sin embargo, según el modelo de campo magnético de la Tierra (una descripción aproximada del campo magnético de la Tierra), el magnetómetro genera grandes errores de medición y no está calificado como sensor de actitud de alta precisión [24] (figura 2).




Figura 2 Magnetómetro.

Un giroscopio mecánico consiste esencialmente en una masa giratoria que gira alrededor de su eje. En particular, cuando la masa gira sobre su eje, tiende a permanecer paralela a sí misma y a oponerse a cualquier intento de cambiar su orientación. Este mecanismo fue inventado en 1852 por el físico Léon Foucault durante sus estudios de la rotación de la Tierra. La aplicación principal de los giroscópicos consiste en la medición de la posición angular del objeto que porta al giroscopio. La masa giratoria está montada sobre un bastidor reforzado, lo que permite la rotación a lo largo de tres ejes perpendiculares [25] (figura 3).




Figura 3 Giroscopio.

En la figura 4 se muestra la medición de las magnitudes de los ejes x , y y z de los tres sensores inerciales de uno de los participantes. Se puede observar que las señales del acelerómetro y del magnetómetro (Fig. 4a y 4b) son representativas de la orientación de la cabeza; ya que cuando el conductor dirige su mirada hacia ciertas zonas de la cabina del vehículo etiquetadas desde S0 hasta S10, se alcanza a distinguir el cambio en las magnitudes de los ejes de estos sensores, sin embargo, en la figura 4c, que corresponde al giroscopio, no es fácil apreciar esta característica. Cabe resaltar que en el siguiente

capítulo se determinará la precisión de la utilización de uno o más sensores para la inferencia del foco de atención de los conductores.

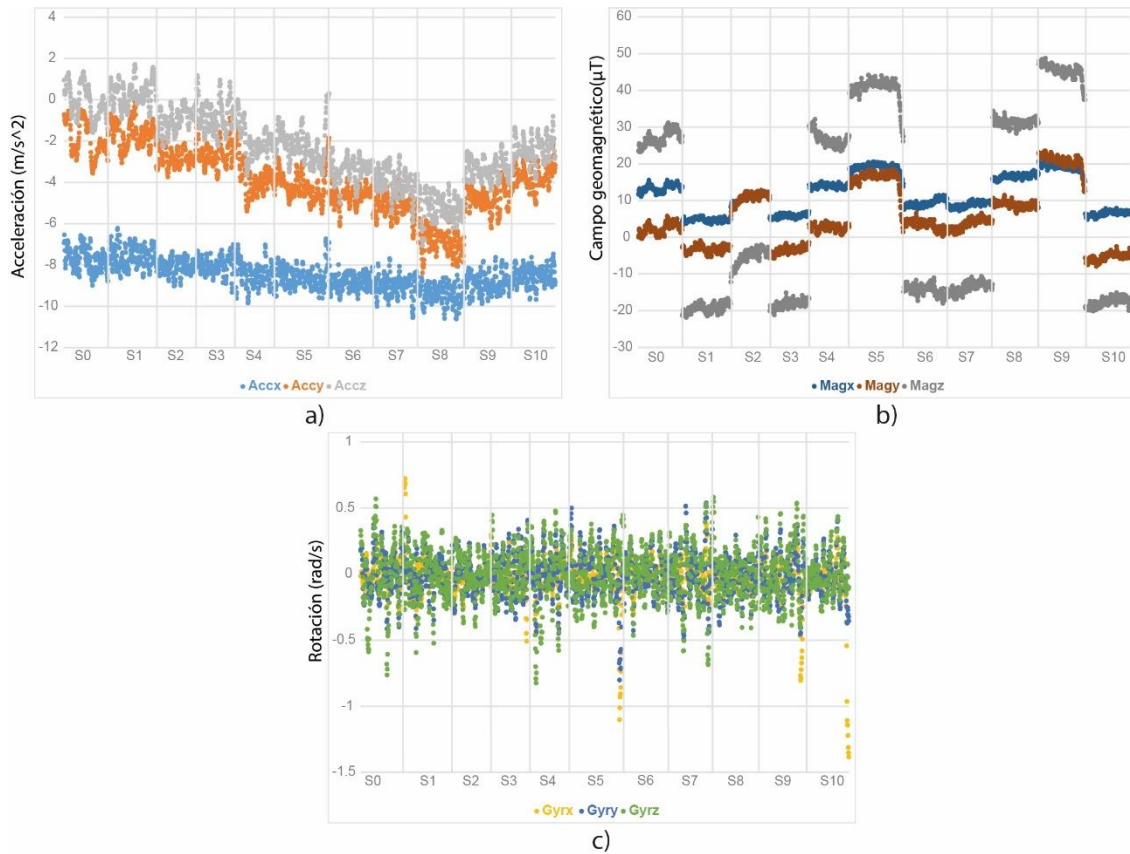


Figura 4 Acelerómetro, Magnetómetro y Giroscopio.

2.1.2 Algoritmos de clasificación y parámetros de configuración

En esta sección, se describen brevemente las técnicas de clasificación supervisada utilizadas en este estudio y los parámetros que se ajustaron para encontrar el mejor rendimiento de clasificación para cada uno de los algoritmos.

Una tarea de clasificación generalmente implica separar los datos en conjuntos de entrenamiento y prueba. Cada instancia en el conjunto de datos de entrenamiento contiene un valor objetivo (es decir, las etiquetas de clase) y varias características (es decir, las variables observadas) [26].

2.1.2.1 Máquinas de Soporte Vectorial (SVM)

La técnica Máquinas de Soporte Vectorial es un clasificador derivado de la teoría del aprendizaje estadístico, es decir, es un método que es comúnmente utilizado para problemas de clasificación y de regresión, y que produce una función o modelo de clasificación a partir del conjunto de datos de entrenamiento. El modelo puede predecir a qué clase pertenece cada una de las instancias del conjunto de datos de prueba [27], además de que con este modelo de clasificación se puede saber a qué clase pertenece una nueva tupla de información. La técnica SVM encuentra el hiperplano lineal que proporciona el margen de separación más significativo entre dos clases. Sin embargo, las clasificaciones por pares se pueden utilizar para abordar problemas de clasificación de varias clases, lo que puede llevar mucho tiempo cuando el conjunto de datos de entrenamiento es grande.

Otra alternativa para problemas multiclase es aplicar métodos basados en el kernel, y uno de los sugeridos es el kernel RBF (Radial Basis Function) [26]. Sin embargo, cuando el número de características es considerable, este kernel puede no ser adecuado. La efectividad de SVM se basa en la selección del kernel y el parámetro de margen blando c . Para el kernel RBF, se deben probar dos parámetros c , además del parámetro de ancho del kernel, a saber, γ . El parámetro c decide el tamaño de clasificación errónea permitido para los datos de entrenamiento no separables, y el parámetro γ afecta el suavizado de la forma del hiperplano de división de clases. Dada la incertidumbre sobre si el tamaño de nuestro conjunto de datos puede considerarse pequeño o grande, decidimos evaluar el SVM comparando su rendimiento al aplicar los kernels lineal y RBF, además de variar el parámetro c .

2.1.2.2 Vecinos cercanos (k -NN)

El algoritmo k -NN [28] es un método de clasificación directa que, a diferencia de otros algoritmos de aprendizaje supervisados como SVM, no produce una función de clasificación desde una etapa de entrenamiento. Simplemente usa el conjunto de datos de

entrenamiento en el momento de la prueba para hacer predicciones. Por lo tanto, k-NN requiere almacenar todo el conjunto de datos. Para clasificar una nueva tupla de información, k-NN utiliza el principio de similitud (distancia euclidiana) entre el conjunto de datos de entrenamiento y la nueva tupla a clasificar. Luego, se asigna a la clase más común a través de un voto mayoritario de sus k vecinos más cercanos.

2.1.2.3 Árboles de decisión (Random Forest RF)

La técnica RF consiste en construir una combinación de árboles de decisión en el momento del entrenamiento [20]. RF mejora el rendimiento de clasificación de un clasificador de árbol único al combinar el método de agregación bootstrap (bagging) y la asignación aleatoria en la selección de nodos de datos de partición en la construcción del árbol de decisión. La asignación de una nueva tupla de información a una clase se basa en el voto mayoritario obtenido de los árboles que constituyen el bosque. RF necesita un gran conjunto de datos de entrenamiento para lograr un buen rendimiento.

2.1.3 Técnicas de entrenamiento de máquinas de aprendizaje

2.1.3.1 Validación Cruzada ('Cross Validation')

En la validación cruzada de k tiempos, los datos iniciales se dividen aleatoriamente en k subconjuntos mutuamente excluyentes o "pliegues", D_1, D_2, \dots, D_K , cada uno aproximadamente del mismo tamaño. Los entrenamientos y pruebas se realizan k veces. En la iteración i , la partición D_i se reserva como el conjunto de prueba y las particiones restantes se usan colectivamente para entrenar el modelo. Es decir, en la primera iteración, los subconjuntos D_2, \dots, D_K sirven colectivamente como el conjunto de entrenamiento para obtener un primer modelo, que se prueba en D_1 ; la segunda iteración se entrena en los subconjuntos D_1, D_3, \dots, D_K y se prueba en D_2 ; y entonces. A diferencia de los métodos de submuestreo de reserva y aleatorio, aquí cada muestra se usa la misma cantidad de veces para entrenamiento y una vez para prueba. Para la clasificación, la

estimación de precisión es el número total de clasificaciones correctas de las k iteraciones, dividido por el número total de tuplas en los datos iniciales [29].

2.1.3.2 División por porcentaje ('Percentage Split')

Con la estrategia División por porcentaje, los datos se dividen en dos grupos, de acuerdo con el porcentaje indicado, con el valor indicado se construye el modelo y a continuación se evalúa con el porcentaje sobrante.

2.1.4 Métricas de desempeño

Las métricas para medir el desempeño de los algoritmos de clasificación implementados utilizadas fueron la Precisión ('Precision'), el Recuerdo ('Recall'), y la Exactitud ('Accuracy') [30]:

Precisión es la proporción de elementos clasificados como positivos que son realmente verdaderos positivos.

$$Precisión = \frac{vp}{vp + fp} \quad (1)$$

Donde vp son los verdaderos positivos y fp los falsos positivos,

Recuerdo ('Recall') es la proporción de elementos verdaderos positivos que son correctamente clasificados como positivos[20].

$$Recuerdo = \frac{vp}{vp + fn} \quad (2)$$

Donde fn son los falsos negativos.

Exactitud ('Accuracy'): es una medida de eficiencia generalizada para evaluar el desempeño de un clasificador, y se refiere a las instancias correctamente clasificadas [20].

$$Exactitud = \frac{vp + vn}{vp + vn + fp + fn} \quad (3)$$

Donde vn son los verdaderos negativos

2.2 TRABAJO RELACIONADO

Con el fin de fundamentar este trabajo de tesis, se realizó una revisión sistemática para identificar la bibliografía especializada y relacionada con esta investigación, tener un conocimiento basto del tema y encontrar formas alternas de abordar esta problemática relacionada a la conducción.

Cabe resaltar que la búsqueda del trabajo relacionado está basada en una Revisión del Alcance ('Scoping Review'), que permite sintetizar la evidencia disponible, con el objetivo de realizar un mapeo del conocimiento permitiéndo obtener una visión general del campo de estudio, debido a la diversidad de artículos y métodos, tratando de responder la siguiente pregunta ¿qué alcance tiene el conocimiento en este campo? La guía utilizada para realizar este Scoping Review, es la elaborada por Arksey y O'Malley [33] la cual consta de cinco etapas. 1.- Identificar la pregunta de investigación, 2.- Identificar los estudios relevantes, 3.- Selección del estudio, 4.- Graficando los resultados y 5.- Cotejar, resumir e informar los resultados.

2.2.1 Método

2.2.1.1 Proceso de búsqueda

Realizamos una búsqueda de literatura relevante que reportará enfoques similares a los que proponemos en este trabajo de tesis y que fueron reportados durante la última década.

Por consiguiente, la estructura de este Scoping Review queda de la siguiente forma:

Se generó una cadena de búsqueda para ser utilizada en la base de datos de SCOPUS. Esta cadena de búsqueda está formada por las palabras ***driver, driving, inattention, distraction drowsy***, ya que estas palabras hacen referencia a la actividad de conducción y también a las posibles causas de un accidente. Por lo tanto, la cadena de búsqueda que se utilizó en SCOPUS quedó estructurada de la siguiente manera **“(DRIVER OR DRIVING) AND (INATTENTION OR DISTRACTION OR DROWSY)”**,

2.2.1.2 Selección de estudio:

Como primer criterio de inclusión, se realizó un filtrado por año, abarcando desde el año 2000 hasta el 2017, ya que anterior al año 2000 no existían dispositivos inteligentes ponibles. El segundo criterio, fue incluir solamente documentos que fueran, artículos, memorias de congresos y capítulos de libros. Como tercer criterio, solo se tomaron en cuenta los documentos del área de Ingeniería y Ciencias Computacionales.

De los documentos seleccionados después de aplicar los tres criterios de inclusión, se realizó un ‘Screening’, mediante el cual, un par de revisores leyeron títulos y resúmenes, para poder identificar aquellos documentos relevantes para esta investigación, Es decir, aquellos que presentaran una tecnología de sensado para monitorear eventos de inatención de conductores. Además de que se agregaron a los documentos seleccionados, algunos otros documentos que fueron identificados durante el proceso mediante la técnica de Snow Ball.

2.2.1.3 Abstracción y análisis de los datos:

El primer dato abstraído de los estudios seleccionados, fue el año de publicación y el tipo de documento, posteriormente se identificaron los enfoques de los estudios,

después, qué era lo que monitoreaban para detectar conductas de inatención, así como los sensores o dispositivos que utilizaban.

2.2.2 Resultados

En la figura 5 se muestra la información recabada por esta Búsqueda del Alcance, el proceso de selección de los artículos utilizados y reportados en esta investigación.

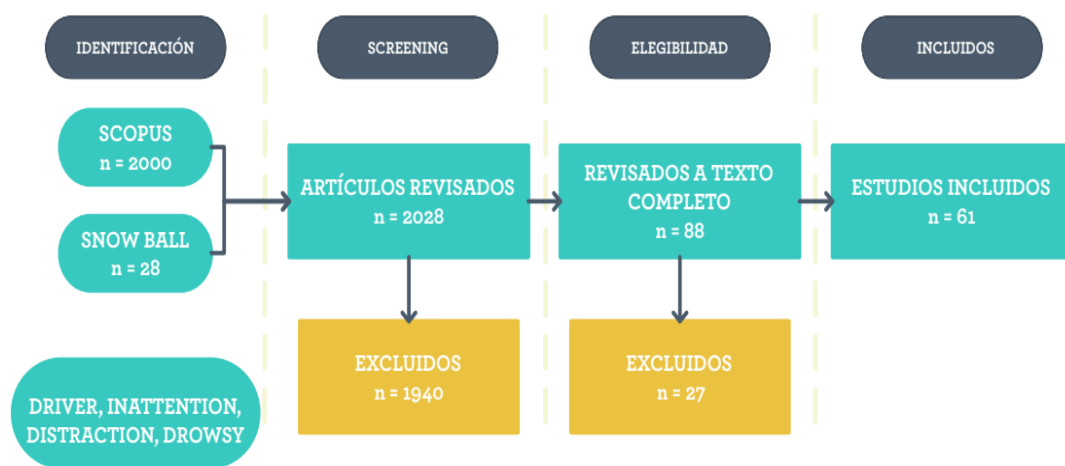


Figura 5 Diagrama de flujo de la Búsqueda de Alcance

Como resultado de la búsqueda, se recuperaron 2000 artículos de SCOPUS, y otros 28 artículos se agregaron al realizar el proceso de SnowBall. De todos estos, 1940 fueron clasificados como no relevantes, por lo que se revisaron a texto completo 88 artículos. Después de la revisión de estos 88 artículos se excluyeron 27 por no cumplir con los criterios de inclusión, quedando finalmente 61 artículos en total [9], [13], [31]–[88]. Las figuras 6-10 muestran los resultados obtenidos a partir de la abstracción de información de cada artículo

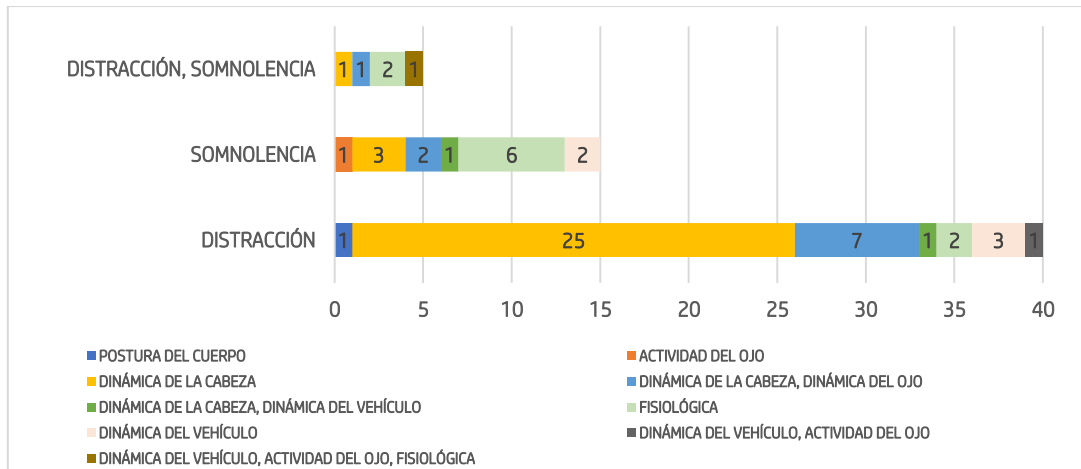


Figura 6 Número de trabajos enfocados en detectar conductas de inatención (eje X), mediante el uso de diferentes técnicas (eje Y).

Como se muestra en la figura 6, la mayoría de los estudios se centran en el comportamiento de distracción [9], [13], [31]–[58], [64], [75], [85]–[88], [69], [81]–[84], para lo cual la señal más estudiada es la dinámica de la cabeza y su movimiento. Por otro lado, la mayoría de los artículos que se centran en inferir la somnolencia utilizan señales fisiológicas, como señales de electroencefalograma (EEG) [13], [32], [42], [53], [64], [75], [85]–[88], [34]–[41], [43], [44], [46]–[52], [54]–[56], [58], [59], [83], [84], electrocardiograma (ECG) [60]–[62], electro-oculografía (EOG) [63] y electromiograma de superficie (sEMG) [62]. Además, pocos trabajos han estudiado la postura de la mano [37] y el cuerpo [51] estos se basan en cámaras para inferir tareas secundarias como comer y hablar por teléfono móvil. Monitorear más de una señal es una estrategia utilizada para mejorar la inferencia de comportamientos de inatención. Por ejemplo, la postura de la cabeza y la dinámica del vehículo se usaron para predecir la distracción [53] y para predecir la somnolencia [65]

Es importante resaltar que la búsqueda toma en cuenta los estudios publicados después del año 2000, ya que anterior a esa fecha no existían los teléfonos inteligentes y mucho menos los dispositivos ponibles.

La figura 7 muestra que existe una tendencia creciente en los últimos años en los cuales se ha incrementado el interés de algunos autores para tratar de inferir los comportamientos riesgosos durante la conducción, también como se puede observar la mayoría de estos estudios ya ha madurado por lo que en fechas más recientes se ha incrementado la publicación de artículos científicos

Es de interés conocer el tipo de enfoque que estudian cada uno de estos artículos en la figura 8 se puede observar que en años recientes se ha incrementado el estudio de la atención en general de los conductores, además de que se han incrementado los estudios relacionados con la somnolencia y las distracciones.




Figura 7 Artículos presentados por año en revista y en conferencias.




Figura 8 Enfoque de los estudios por año

Es conveniente realizar un análisis de la metodología seguida por estos autores para conocer cómo se pretende abordar la problemática, es por ello, que en la figura 9 se muestran cada una de las metodologías utilizadas para los diferentes enfoques de investigación.




Figura 9 Tipos de enfoques de investigación

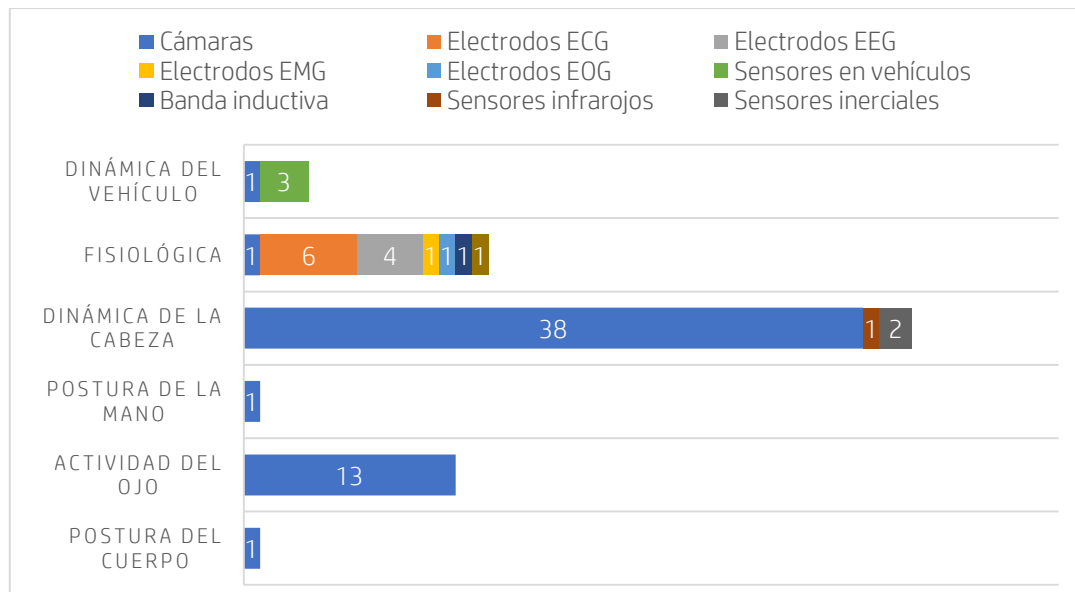


Figura 10 Sensores o dispositivos utilizados para abordar la problemática

El tipo de sensores utilizados para resolver y/o analizar el problema de distracción se muestra en la figura 10. Se puede observar que la mayoría de los trabajos se enfocan en estudiar la dinámica de la cabeza mediante el uso de cámaras. Mientras que analizar distracciones mediante la postura de la mano, del cuerpo o la dinámica del vehículo es poco utilizada. La cámara es el sensor más utilizado (en 55 trabajos) y en menor uso los electrodos, sensores infrarrojos o sensores inerciales.

Cabe resaltar que los artículos en los que utilizan sensores inerciales, uno detecta la postura de las articulaciones del cuerpo [46], y el otro utiliza solamente un sensor inercial para determinar la orientación de la cabeza con respecto a la orientación del vehículo [53]. También se puede observar en la figura 10, que 15 artículos están orientados a detectar las características fisiológicas del conductor utilizando electrodos mientras conduce. De lo anterior, se identificó la oportunidad de explorar el uso de sensores inerciales embebidos en dispositivos usables (e.g., lentes inteligentes) para detectar la postura de la cabeza.

Capítulo 3

3. ESTUDIOS PREVIOS DE FACTIBILIDAD DE LOS SENSORES

3.1 IMPACTO DE LAS TÉCNICAS DE ENTRENAMIENTO DE MÁQUINAS DE APRENDIZAJE EN LA INFERENCIA DEL FOCO DE ATENCIÓN

3.1.1 Método

3.1.1.1 Participantes

Para el desarrollo del estudio de factibilidad de los sensores, solamente se utilizó a un participante, en este caso el autor de este documento fue el participante de quién se recolectaron los datos de la conducción.

El conjunto de datos recolectados representa una hora de conducción a 3 diferentes velocidades para evaluar el efecto de la velocidad del vehículo en las mediciones de los sensores. Por ello, la recolección de datos se realizó por las noches en un horario de 11:00 pm a 12:00 am, aprovechando el horario en que la mayor parte de la ciudad se encuentra con muy poca afluencia vehicular.

3.1.1.2 Actividad de la sesión de conducción

En todas las sesiones el conductor estuvo acompañado de un copiloto. Mientras el conductor realizaba la tarea de conducción, el copiloto era el encargado de iniciar y detener la captura de los sensores inerciales, esta actividad se realizaba a través de un teclado bluetooth vinculado con el dispositivo de captura y portador de los sensores.

Se utilizaron dos dispositivos para realizar la captura de los datos de los sensores inerciales, un Google Glass y un teléfono inteligente. Debido a que la batería del Google Glass dura aproximadamente 2 horas en funcionamiento, todos los datos que se muestran

en esta tesis fueron capturados con el teléfono inteligente. Una de las condiciones que se tomaron en cuenta para utilizar solo el teléfono inteligente es que ambos dispositivos funcionan con el sistema operativo Android, y la aplicación utilizada puede ejecutarse en ambos dispositivos, además de que el principio de funcionamiento de los sensores inerciales de ambos dispositivos es el mismo.

Tomando como base la zona de la cabina del vehículo que visualizan los conductores, se seleccionaron aquellas zonas donde comúnmente se observa durante la conducción, ya sea para realizar tareas propiamente de la conducción o tareas secundarias que impliquen una distracción. Como se observa en la figura 11, las zonas del vehículo se etiquetaron como spot S0, S1, S2 hasta spot S10.

El copiloto solicitaba al conductor que observara por 4 segundos cada uno de los puntos de la cabina del vehículo previamente seleccionados. En la figura se muestran los distintos puntos de la cabina del vehículo a los cuales se le solicitaba al conductor fijar su atención.

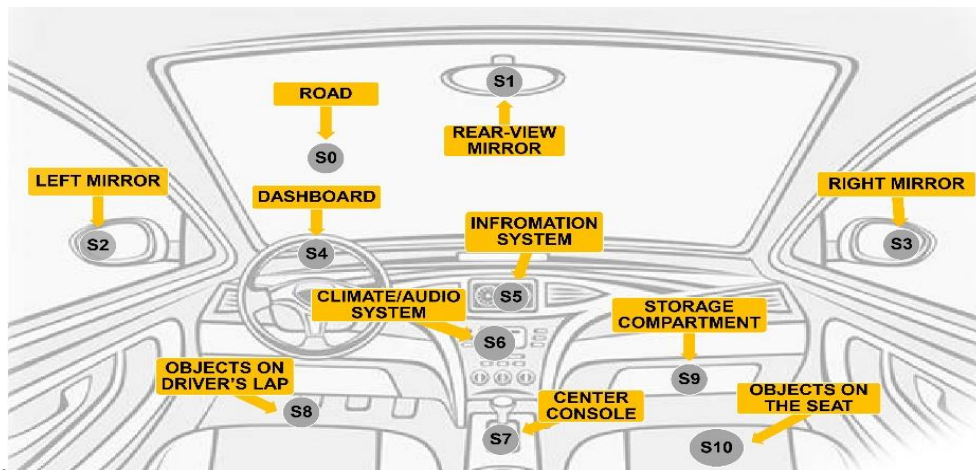


Figura 11 Cabina del vehículo etiquetada con los spots desde el S0 hasta el S10.

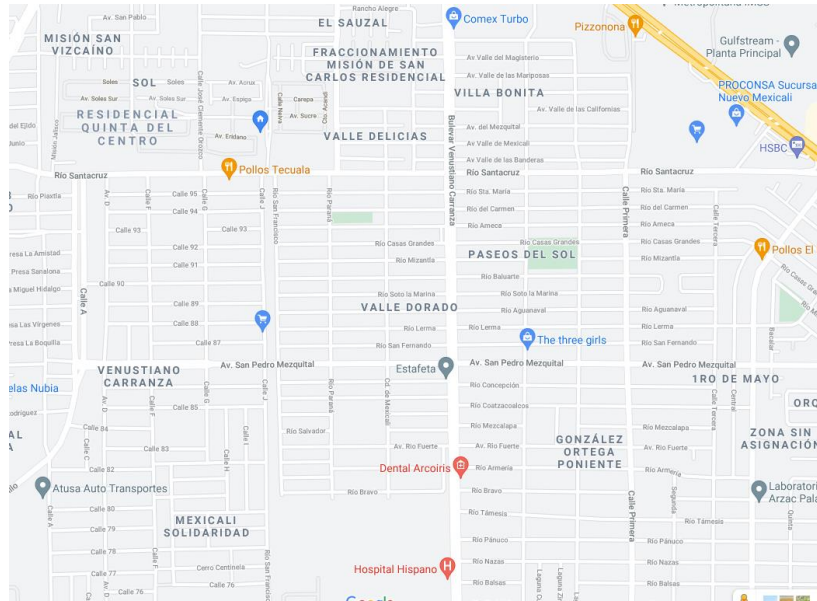


Figura 12 Bulevar de conducción, para evaluar el impacto de la velocidad en los datos.

Para poder evaluar el impacto de la velocidad de conducción en los datos de los sensores, se condujo sobre el boulevard Venustiano Carranza, de la ciudad de Mexicali, el tramo que se muestra en la figura 12 a las velocidades de 20,30 y 40 km/h.

3.1.1.3 Instrumentación

El conductor utilizó un sombrero en el cual se colocaba el teléfono inteligente para capturar la información de la postura de su cabeza al momento de realizar las tareas solicitadas durante el proceso de conducción. La figura 13 muestra una imagen del uso del dispositivo en el conductor.



Figura 13 Conductor portando el sombrero durante la conducción.

3.1.1.4 Propiedades del conjunto de datos

Toda la información capturada por los sensores inerciales, está conformada por tuplas (ver figura 14). Cada una de ellas contiene los valores x , y y z del acelerómetro (Accx, Accy, Accz), magnetómetro (Magx, Magy, Magz) y giroscopio (Gyrx, Gyry, Gyrz); Además de la marca de tiempo en la que fueron adquiridos. Cada tupla fue etiquetada con la clase spot (S0-S10, según corresponda) a través de la aplicación Java.

ACELERÓMETRO			GIROSCOPIO			MAGNETÓMETRO			Time	Class
Accx	Accy	Accz	Gyrx	Gyry	Gyrz	Magx	Magy	Magz		
-6.924	6.213	1.666	-0.016	0.195	0.151	11.7	-11.64	23.46	1.5+E12	So
-6.539	5.753	1.228	-0.011	0.197	0.107	11.88	-11.4	22.92	1.5+E12	So
...
-7.295	6.285	1.262	0,015	0.215	0.015	13.02	-10.74	23.28	20+E12	S5
...
-7.791	6.745	1.291	0.02	0.207	0.006	13.26	-10.98	22.62	40+E12	S10

Figura 14 Ejemplo de las tuplas de información capturadas durante una sesión de conducción.

3.1.1.5 Entrenamiento y prueba de la Máquina de inferencia

La plataforma utilizada para entrenar y probar el rendimiento de SVM, k-NN y RF fue WEKA (Waikato Environment for Knowledge Analysis, versión 3.8.2) [89]. WEKA ofrece una colección de algoritmos de aprendizaje automático para tareas de minería de datos. Además, contiene herramientas para pre procesamiento de datos, clasificación, regresión, clustering, reglas de asociación y visualización. Adicionalmente se utilizó la funcionalidad de WEKA para normalizar los datos.

3.1.1.6 Configuraciones de la Máquina de inferencia

Para realizar el entrenamiento y la clasificación de los datos, la máquina de inferencia se configuró para identificar qué tipo de entrenamiento requieren los algoritmos de inteligencia artificial para obtener los mejores resultados. Los datos recolectados se utilizaron para el entrenamiento de una SVM, y evaluados con un kernel lineal en Percent Split y Cross-Validation.

3.1.2 Resultados

Como se observa en la figura 15, la técnica Cross-Validation es la que ofrece una mejor clasificación de los datos, por lo tanto, será la técnica que se utilizará en los futuros métodos.




Figura 15 Comparación entre Cross-Validation y Percent Split.

3.2 IMPACTO DE LA VELOCIDAD Y ORIENTACIÓN DEL AUTOMÓVIL EN LA INFERENCIA DEL FOCO DE ATENCIÓN

3.2.1 Método

Los datos recolectados durante la actividad de conducción se componen de 3 velocidades diferentes (20,30 y 40 km/h), y se realizaron entrenamientos personalizados para cada una de las velocidades y al final un entrenamiento generalizado, en el cual se unieron todos datos de las tres velocidades.

Para la captura de los datos se realizaron tres recorridos de la misma ruta a las tres velocidades diferentes (figura 12). En la figura 16, se observa el resultado de los datos capturados con estas 3 velocidades.

Cada una de las velocidades fue recabada en días diferentes, tomando en cuenta la condición que se mencionó en la sección 3.1.1

3.2.2 Resultados

Como podemos observar en la figura 16, indistintamente de la velocidad a la que se conduzca, el algoritmo de clasificación no presenta una variación significativa.

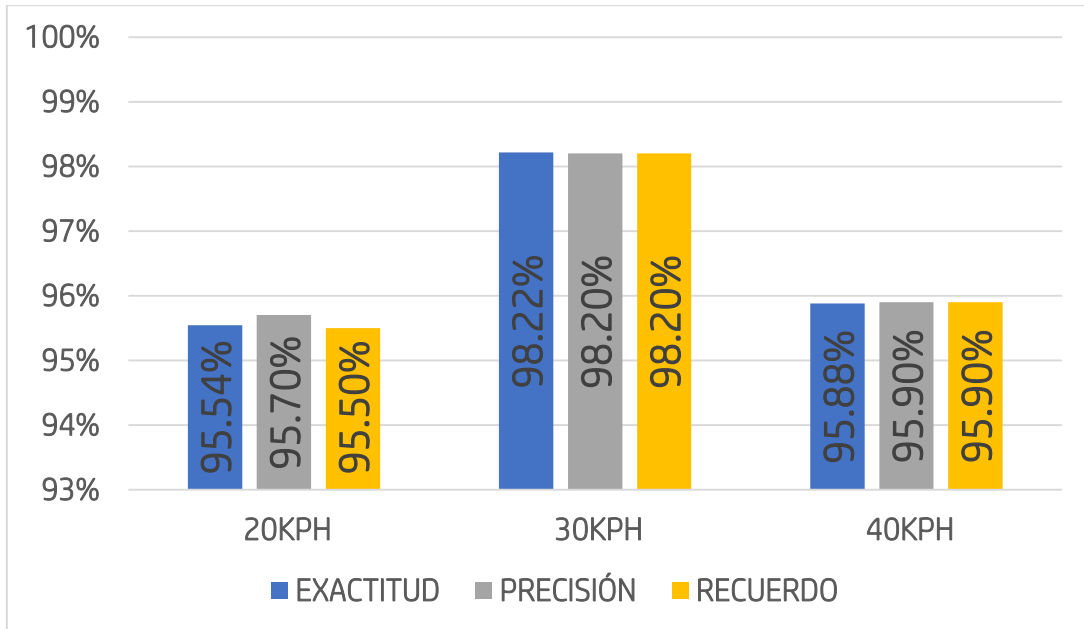


Figura 16 Velocidades de conducción.

La dirección de la conducción del vehículo (ya sea hacia el norte o hacia el sur) tampoco influye en los resultados de clasificación, como se muestran en las figuras 17 y 18.




Figura 17 Direcciones de conducción.




Figura 18 Conducción en ambas direcciones.

3.3 Discusión

En este capítulo se demostró la factibilidad de utilizar datos recolectados de sensores inerciales para inferir el comportamiento riesgoso durante la conducción.

Además, se demuestra que tanto la velocidad como la orientación del vehículo pueden despreciarse dado que no representan un cambio en el proceso de clasificación de los puntos de interés a los cuales voltea el conductor al momento de realizar la tarea de conducción.

Con esta evaluación del comportamiento de los sensores bajo características de velocidad y orientación diferentes, podemos concluir que la técnica más adecuada para la evaluación del desempeño del algoritmo de inteligencia artificial tiene que realizarse utilizando la técnica de Cross-Validation.

Capítulo 4

4. MÉTODO PARA DETERMINAR LA INFERENCIA DEL FOCO DE ATENCIÓN

4.1 PARTICIPANTES

Para evaluar la inferencia del foco de atención se reclutaron diez participantes (P1-P10), seis hombres y cuatro mujeres, con una edad media de $M=31.5$ años y una desviación estándar de $DE=9.05$ años. Los criterios de inclusión que se tomaron en cuenta fue que los sujetos tuvieran la mayoría de edad (>18 años), contaran con licencia de conducir vigente y que aceptaran conducir el mismo vehículo disponible para el estudio, el cual es de transmisión estándar. Se pidió a los participantes tener disponibilidad para la recolección de datos de 1 hora aproximadamente, y que preferentemente pudieran participar por la tarde noche, en el horario que les más pareciera adecuado.

Todos los participantes, previo a la realización de la actividad de recolección de datos, fueron capacitados e informados de la tarea y actividades de conducción que tenían que realizar durante el recorrido en el vehículo. Con lo anterior, se confirma que proporcionaron su consentimiento para aceptar las condiciones del estudio, lo que incluía portar los sensores inerciales en sus cabezas durante el recorrido predefinido.

El promedio de la duración de la recolección de datos de todos los participantes fue de 35 minutos, además de 20 minutos que tomó explicarles las actividades a realizar previo a la sesión.

4.2 ACTIVIDADES PARA RECOLECTAR DATOS

El vehículo que se condujo para recolectar datos fue un vehículo de la marca NISSAN, modelo sentra 2006 de transmisión manual. Todas las sesiones fueron

desarrolladas conduciendo un mismo vehículo dentro de un estacionamiento (con el fin de garantizar la seguridad de los conductores). En la figura 19, se observa el estacionamiento donde realizaron la conducción los 10 participantes.



Figura 19 Ruta seguida por los participantes durante las sesiones de conducción en el estacionamiento privado.

Se controlaron las condiciones del estudio para recolectar datos, de tal manera que todos los participantes condujeron dentro del mismo estacionamiento. Además, todos los participantes estuvieron acompañados por un copiloto durante el experimento quién controlaba los instrumentos de recolección de datos. Los participantes recibieron instrucciones de fijar su mirada en cada uno de los lugares de la cabina durante aproximadamente 2-3 segundos, y repetirlo tres veces durante la sesión. Solo se les pidió que voltearan a ver los puntos de la cabina mientras conducían en dirección recta.

4.3 DESCRIPCIÓN DEL CONJUNTO DE DATOS

Como se muestra en la Tabla 1, en total se recolectamos 19,521 lecturas de los sensores de inerciales. Sin embargo, podemos observar que los subtotales de cada participante son diferentes, esto se debe a que el tiempo que el participante dirigió su

mirada hacia ese spot tuvo variaciones de tiempo, es decir, algún participante observó por más tiempo hacia ese spot.

Tabla 1 Datos recolectados.

Participante/Spot de la Cabina	S0	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	Sub- total
P1	164	146	165	168	200	164	178	170	154	230	173	1912
P2	158	151	187	182	157	208	178	203	179	183	227	2013
P3	213	165	172	151	151	174	165	148	177	161	205	1882
P4	161	177	143	144	147	198	160	166	168	171	163	1798
P5	217	211	200	172	207	179	166	177	194	177	173	2073
P6	173	188	188	237	172	230	238	225	207	250	248	2356
P7	164	154	177	154	179	158	196	195	184	189	173	1923
P8	186	172	164	168	151	171	170	159	193	243	170	1947
P9	190	222	173	126	151	187	180	163	170	168	185	1915
P10	143	153	167	150	152	155	143	173	160	145	161	1702
TOTAL	1769	1739	1736	1652	1667	1824	1774	1779	1786	1917	1878	19521




Figura 20 Datos capturados en cada spot por participante.

En la figura 20 se ilustra la cantidad de datos capturados por cada uno de los spots que observó cada participante. No todos los participantes mantuvieron la mirada fija la misma cantidad de tiempo, esto se ve reflejado en que los datos no son completamente balanceados para cada uno de los spots. Sin embargo, este desbalanceo no se considera significativo para causar una diferencia notable en los resultados por los métodos de clasificación.

Cabe destacar que el conjunto de datos son valores crudos (raw data) de cada uno de los ejes de los 3 sensores utilizados. Así que, para cada uno de los spots y cada tupla perteneciente a éste, tenemos las magnitudes de x, y y z del acelerómetro, magnetómetro y giroscopio.

Capítulo 5

5. RESULTADOS

5.1 ANALISIS DE LA INFERENCIA DEL FOCO DE ATENCIÓN UTILIZANDO LA TÉCNICA SVM

Como se muestra en la figura 21, la técnica SVM con un kernel lineal produce el mejor resultado para $c = 8$, con una precisión de 26.71% y un $RMSE = 27.97\%$. Se observa que los valores $RMSE$ cambian ligeramente para todos los valores de c evaluados; es decir, en promedio, el $RMSE$ es $M = 28.06\%$ con una varianza de $S^2 = 0.007$.

La SVM con el kernel RBF muestra que la precisión mejora cuando aumenta el valor de c (ver figura 22). Obtuvimos la mejor precisión (98.82%) cuando $c = 128$ y $\gamma = 16$, con un valor de $RMSE = 26.31\%$. El valor de $RMSE$ cambia ligeramente para todos los valores probados de c y γ ($M = 27.07\%$, $S^2 = 1.02$). Por lo tanto, la SVM con el método del núcleo RBF muestra una mayor precisión que el SVM lineal.




Figura 21 Desempeño de la SVM con un kernel Lineal.

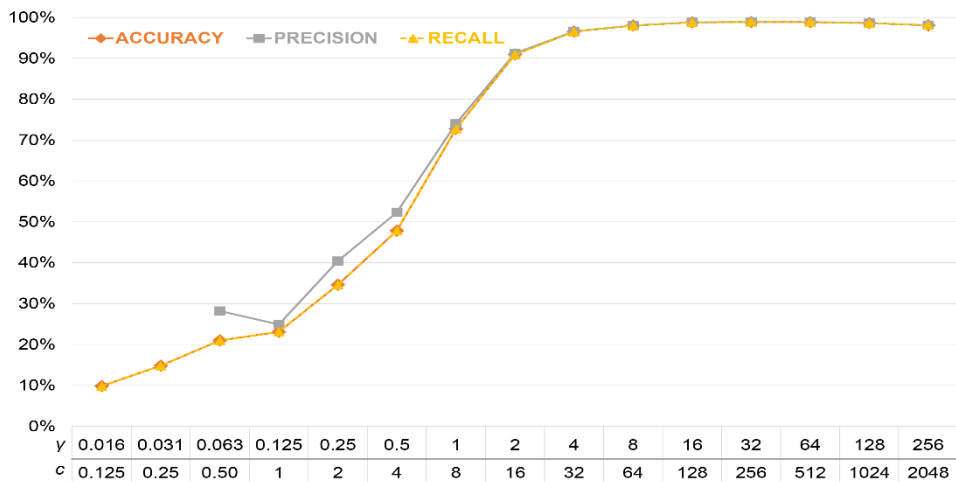


Figura 22 Desempeño de la SVM con un kernel RBF.

5.2 ANALISIS DE LA INFERENCIA DEL FOCO DE ATENCIÓN UTILIZANDO LA TÉCNICA k-NN

En el caso del algoritmo k-NN, se obtuvo la mejor precisión (96.90%) y el valor de error más bajo ($RMSE = 7.5\%$) para $k = 1$ (ver figura 23). Encontramos que a medida que aumenta el valor de k , la precisión disminuye mientras que el RMSE aumenta ligeramente ($M = 9.731\%$, $S^2 = 1.684$).




Figura 23 Desempeño de k -NN.

5.3 ANALISIS DE LA INFERENCIA DEL FOCO DE ATENCIÓN UTILIZANDO LA TÉCNICA RF

Como se presenta en la figura 24, todas las evaluaciones aplicando la técnica RF dieron como resultado una precisión superior al 90%. El mejor rendimiento se obtuvo para 1200 árboles con una precisión de 98.65% con un $RMSE = 5.26\%$. Los valores RMSE fueron casi constantes para todas las variaciones en el número de árboles, presentando así una varianza baja ($M = 5.27\%$, $S^2 = 10.00032 M$).

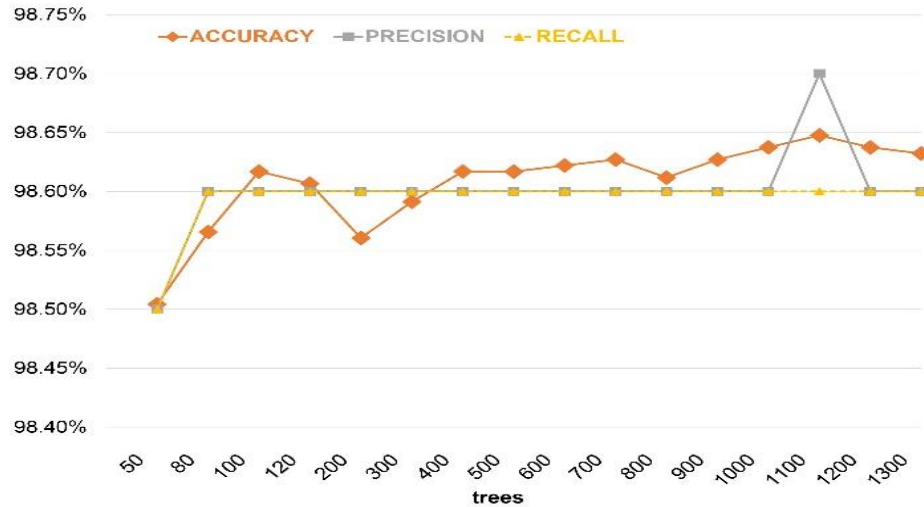


Figura 24 Desempeño de Random Forest.

5.4 COMPARACIÓN DE LAS MÁQUINAS DE CLASIFICACIÓN

La tabla 2 compara los resultados obtenidos de cada clasificador en función de las métricas de rendimiento utilizadas para este estudio. Concluimos que todos los clasificadores, excepto la técnica SVM lineal, muestran una precisión, exactitud y recuperación superiores al 96%. Además, los clasificadores se comportan de manera similar de acuerdo con las matrices de confusión presentadas en la figura 25. En todos los casos, los clasificadores tienden a confundir las instancias de las mismas clases spot; es decir, S0 con S4 (tablero de instrumentos), S9 (compartimento de almacenamiento) con S10 (asiento del pasajero) y S6 (sistema de clima / audio) con S7 (consola central). Sin embargo, la técnica RF presenta el RMSE más bajo; mientras que la técnica SVM (kernel RBF) proporciona la mejor precisión, pero con un RMSE más alto. Consideramos que para implementar el modelo basado en SVM (kernel RBF) se deben realizar más experimentos para evaluar la viabilidad de reducir el RMSE mediante el uso de diferentes valores para

los parámetros de ajuste. Por otro lado, para implementar el modelo RF, se debe considerar un número menor de árboles de decisión como los utilizados en, [61] y [27] en los que se obtuvo una precisión similar a la obtenida con 1200 árboles de decisión (ver figura 24). En este caso, se necesita un análisis adicional para determinar el número óptimo de árboles, es decir, aumentar el número de árboles no generaría una ganancia de rendimiento significativa, solo aumentaría el costo computacional.

Tabla 2 Comparación de las métricas de desempeño de las técnicas de clasificación.

MÉTRICA	SVM (RBF)	SVM (LINEAL)	k-NN	RF
Exactitud (%)	98.82	26.71	96.90	98.65
Precisión (%)	98.80	30.10	96.90	98.70
Recuerdo (%)	98.80	26.70	96.90	98.60
RMSE (%)	26.31	27.97	7.5	5.26

SVM (RBF)											
S0	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	<-- CLASSIFIED AS
1754	3	0	0	12	0	0	0	0	0	0	S0
7	1728	0	0	1	2	1	0	0	0	0	S1
0	0	1736	0	0	0	0	0	0	0	0	S2
0	1	0	1642	0	1	0	4	0	4	0	S3
36	0	0	0	1630	0	0	0	0	0	1	S4
1	6	0	0	0	1801	15	0	1	0	0	S5
0	3	0	0	0	9	1741	12	6	3	0	S6
0	0	0	1	0	0	21	1753	1	3	0	S7
0	0	0	0	1	1	6	0	1772	6	0	S8
0	1	0	2	0	1	1	1	1	1890	20	S9
0	0	0	0	0	0	0	0	0	34	1844	S10

SVM (LINEAR)											
S0	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	<-- CLASSIFIED AS
1025	129	135	2	27	173	9	57	189	9	14	S0
457	396	95	152	29	74	12	321	152	47	4	S1
436	108	67	178	107	176	5	258	168	204	29	S2
484	65	5	424	14	146	2	19	151	340	2	S3
550	139	26	2	177	248	8	153	150	192	22	S4
171	239	8	126	63	298	113	334	116	344	12	S5
191	146	35	3	8	94	319	733	62	165	18	S6
80	32	11	0	75	14	80	978	301	196	12	S7
31	51	27	0	11	160	109	438	849	44	66	S8
113	73	27	166	86	139	21	774	52	466	0	S9
186	35	21	23	64	323	15	475	162	358	216	S10

RANDOM FOREST											
S0	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	<-- CLASSIFIED AS
1749	0	0	0	20	0	0	0	0	0	0	S0
9	1712	1	3	4	7	3	0	0	0	0	S1
0	0	1736	0	0	0	0	0	0	0	0	S2
0	0	0	1638	0	3	0	8	0	3	0	S3
44	0	0	0	1621	0	0	0	2	0	0	S4
1	7	0	0	0	1796	19	0	1	0	0	S5
0	2	0	0	0	13	1737	14	5	3	0	S6
0	0	0	1	0	0	16	1758	0	4	0	S7
0	1	0	0	0	1	6	0	1776	0	2	S8
0	2	0	5	0	5	7	5	4	1873	16	S9
0	0	0	1	0	0	0	0	0	16	1861	S10

k-NN											
S0	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	<-- CLASSIFIED AS
1741	2	0	0	26	0	0	0	0	0	0	S0
18	1688	0	9	8	11	5	0	0	0	0	S1
0	0	1735	1	0	0	0	0	0	0	0	S2
4	3	0	1621	0	4	0	9	0	11	0	S3
37	1	0	1	1619	0	3	0	6	0	0	S4
0	13	0	1	1	1735	69	0	3	2	0	S5
0	3	0	0	0	60	1670	17	12	10	2	S6
0	2	0	0	0	2	14	1728	1	25	7	S7
0	1	0	0	7	10	8	0	1750	10	0	S8
0	0	0	8	0	10	7	13	3	1833	43	S9
0	0	0	1	0	0	6	10	1	64	1796	S10

Figura 25 Matrices de confusión obtenidas de cada clasificador.

Capítulo 6

6. CONCLUSIONES

6.1 CONTRIBUCIONES

La información y conocimiento adquiridos durante el desarrollo de este trabajo de tesis permitió generar las siguientes contribuciones que se pueden clasificar en dos tipos. Las primeras se asocian a las preguntas de investigación:

- PI1: ¿Utilizar datos crudos obtenidos de sensores inerciales son suficientes para inferir el foco de atención de los conductores?

Con el estudio presentado se demuestra que los datos crudos de los sensores inerciales son adecuados para inferir el foco de atención de los conductores [90], siempre y cuando los sensores se utilicen bajo condiciones similares a las utilizadas en este estudio. Por lo tanto, no es posible generalizar resultados de esta tesis.

- PI2: ¿Cuál de las 3 técnicas de inferencia seleccionadas es la más adecuada para inferir el foco de atención del conductor durante la conducción?

De acuerdo a los resultados, la recomendación es utilizar SVM(RBF) si se requiere generar un modelo generalizado para una aplicación particular, ya que esta proporciona la mejor precisión. Sin embargo, para aplicaciones que requieren modelos personalizados, tal como en el trabajo presentado en [91], se recomienda utilizar K-NN el cual es un algoritmo de tipo “lazy” que requiere datos de entrenamiento en memoria sin generar un modelo clasificador a partir de estos.

El segundo tipo de contribuciones son los productos de esta tesis, que incluyen los siguientes:

- El primero de ellos se encuentra publicado en la revista IEEE Access, en el vol. 7, y las páginas de la 185422 a la 185432, en diciembre de 2019, <https://ieeexplore.ieee.org/document/8936432>.
- El segundo se encuentra publicado en MDPI proceedings 2 en el año de 2018 en el volumen 19, páginas 1259, <https://www.mdpi.com/2504-3900/2/19/1259>.
- El tercero se encuentra publicado en la revista Ambient Intelligence and Humanized Computing del año 2020, <https://link.springer.com/article/10.1007/s12652-020-01732-6>.

6.2 LIMITACIONES DE LOS ESTUDIOS

Una de las limitaciones de este estudio es que no se exploraron otras técnicas de inferencias como, por ejemplo, deep learning o extreme learning. Por lo tanto, se desconoce si estas otras técnicas podrían ayudar a mejorar los resultados de este estudio el cual fue realizado en condiciones controladas. La anterior hipótesis persiste ya que trabajos similares han experimentado con estas técnicas en condiciones controladas. Como por ejemplo, en [92], se utiliza sensores inerciales y Redes Neuronales Profundas (Deep Neuronal Network) y Redes Neuronales Convolucionales (Convolutional Neuronal Network) para identificar posturas inadecuadas de la cabeza al estar, por ejemplo, sentado en una oficina. En este trabajo obtienen mayores precisiones con las técnicas de aprendizaje profundo (93%-95%) que, con técnicas de máquinas de aprendizaje, tal como SVM (85.9%) o k-NN (86.4%).

Otra de las limitantes de los estudios de esta tesis, es que no se utilizaron técnicas de procesamiento de datos, tal como generar Cuaterniones a partir de los datos crudos de los sensores. Se considera que el utilizar esta técnica podría ayudar a lidiar con el movimiento del vehículo lo cual puede afectar la inferencia del foco de atención de la conducción.

6.3 TRABAJO A FUTURO

El uso de dispositivos móviles con mayores capacidades computacionales, tal como los Attitude and Heading Reference Systems (AHRS) [93]. Este tipo de dispositivos proporcionan las características necesarias para obtener un ángulo de dirección relativo al vehículo. Lo anterior podría ayudar a generar modelos que puedan predecir en diferentes condiciones del ambiente (p.ej. rotondas, pendientes, caminos sinuosos).

En cierto momento de nuestro estudio se evaluó la precisión de las máquinas de inferencia con respecto a la cantidad de sensores necesarios para inferir el foco de atención de los conductores, obteniendo como resultado que el utilizar los tres sensores permite obtener una mayor precisión (ver Apéndice A)

De lo anterior se propone como trabajo a futuro experimentar con una menor cantidad de sensores para comprender cómo se afecta el consumo de energía del dispositivo. Creemos que valdría la pena realizar un estudio más detallado que permita proponer alguna técnica que facilite ajustar el uso de los sensores con base a las condiciones del ambiente y de la conducción.

Además, el hecho de realizar un pre-procesamiento de los datos podría tener como consecuencia un mayor uso del procesador del dispositivo que se esté utilizando para la captura, esto implicaría un mayor consumo de energía y se requeriría de mayor capacidad de cómputo del dispositivo.

También como se muestra en el apéndice B, en el transcurso de esta tesis se exploraron otras áreas de oportunidad que involucran el uso de vehículos instrumentados con múltiples sensores y sistemas de comunicación para evaluar aspectos de comunicación en redes ad-hoc formados por estos vehículos. Los resultados obtenidos podrían ayudar a identificar requerimientos de diseño para implementar un sistema de difusión o propagación del foco de atención de los conductores. Lo anterior podría ayudar a generar sistemas de predicción de riesgos, tal como algún accidente, que pudiera afectar a más conductores

Referencias

- [1] S. S and G. G. Ray, "Human factors in safe driving-A review of literature on systems perspective, distractions and errors," *Proc. - 2012 IEEE Glob. Humanit. Technol. Conf. GHTC 2012*, pp. 83–88, 2012, doi: 10.1109/GHTC.2012.22.
- [2] A. Aaft, "Las distracciones normales en la conducción," vol. 501, no. c, 2006.
- [3] S. G. Klauer *et al.*, "The Impact of Driver Inattention On Near Crash/Crash Risk: An Analysis Using the 100-Car Naturalistic Driving Study Data," *Analysis*, no. April, p. 226, 2006.
- [4] P. N. Trace, "Review of crash effectiveness of Intelligent Transport Systems Table of Contents," no. 027763, pp. 1–131, 2007.
- [5] H.-B. Kang, "Various Approaches for Driver and Driving Behavior Monitoring: A Review," in *2013 IEEE International Conference on Computer Vision Workshops*, Dec. 2013, pp. 616–623, doi: 10.1109/ICCVW.2013.85.
- [6] G. Urzaiz, S. F. Ochoa, C. Rica, and D. Hutchison, *LNCS 8276 - Ubiquitous Computing and Ambient Intelligence*, no. December. 2013.
- [7] G. Glass and J. He, "Smart glasses : Driver distraction or safety tool ?," pp. 1–2, 2017.
- [8] L. Zhang, F. Liu, and J. Tang, "Real-Time System for Driver Fatigue Detection by RGB-D Camera," *ACM Trans. Intell. Syst. Technol.*, vol. 6, no. 2, pp. 1–17, Mar. 2015, doi: 10.1145/2629482.
- [9] E. Murphy-Chutorian and M. M. Trivedi, "Head pose estimation and augmented reality tracking: An integrated system and evaluation for monitoring driver awareness," *IEEE Trans. Intell. Transp. Syst.*, vol. 11, no. 2, pp. 300–311, 2010, doi: 10.1109/TITS.2010.2044241.

- [10] S. Africa, "The Guardian System reduces fatigue and distraction events."
- [11] Y. F. Zhang, X. Y. Gao, J. Y. Zhu, W. L. Zheng, and B. L. Lu, "A novel approach to driving fatigue detection using forehead EOG," *Int. IEEE/EMBS Conf. Neural Eng. NER*, vol. 2015-July, pp. 707–710, 2015, doi: 10.1109/NER.2015.7146721.
- [12] A. Cenedese, L. Minetto, G. A. Susto, and M. Terzi, "Human activity recognition with wearable devices: A symbolic approach," *PsychNology J.*, vol. 14, no. 2–3, pp. 99–115, 2016.
- [13] A. Tawari, S. Martin, and M. M. Trivedi, "Continuous head movement estimator for driver assistance: Issues, algorithms, and on-road evaluations," *IEEE Trans. Intell. Transp. Syst.*, vol. 15, no. 2, pp. 818–830, 2014, doi: 10.1109/TITS.2014.2300870.
- [14] A. Vecchio, F. Mulas, and G. Cola, "Posture Recognition Using the Interdistances Between Wearable Devices," *IEEE Sensors Lett.*, vol. 1, no. 4, pp. 1–4, 2017, doi: 10.1109/lsens.2017.2726759.
- [15] B. Metz and H. P. Krueger, "Measuring visual distraction in driving: The potential of head movement analysis," *IET Intell. Transp. Syst.*, vol. 4, no. 4, pp. 289–297, 2010, doi: 10.1049/iet-its.2009.0116.
- [16] B. R. Raiff, Ç. Karataş, E. A. McClure, D. Pompili, and T. A. Walls, "Laboratory validation of inertial body sensors to detect cigarette smoking arm movements," *Electronics*, vol. 3, no. 1, pp. 87–110, 2014, doi: 10.3390/electronics3010087.
- [17] C. Karatas *et al.*, "Leveraging wearables for steering and driver tracking," *Proc. - IEEE INFOCOM*, vol. 2016-July, 2016, doi: 10.1109/INFOCOM.2016.7524544.
- [18] J. K. Caird, K. A. Johnston, C. R. Willness, and M. Asbridge, "The use of meta-analysis or research synthesis to combine driving simulation or naturalistic study results on driver distraction," *J. Safety Res.*, vol. 49, pp. 91.e1-96, Jun. 2014, doi: 10.1016/j.jsr.2014.02.013.
- [19] P. li and C. F. Experiment, "Trial begins to investigate efficacy of monoclonal

- antibody against schizophrenia,” *Pharm. J.*, no. April, 2017, doi: 10.1211/pj.2017.20203911.
- [20] Y. L. Pavlov, “Random forests,” *Random For.*, pp. 1–122, 2019, doi: 10.1201/9780429469275-8.
- [21] F. Attal *et al.*, “Physical Human Activity Recognition Using Wearable Sensors,” *Sensors*, vol. 15, no. 12, pp. 31314–31338, Dec. 2015, doi: 10.3390/s151229858.
- [22] P. Thanh Noi and M. Kappas, “Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery,” *Sensors*, vol. 18, no. 2, p. 18, Dec. 2017, doi: 10.3390/s18010018.
- [23] A. Fernández, R. Usamentiaga, J. L. Carús, and R. Casado, “Driver distraction using visual-based sensors and algorithms,” *Sensors (Switzerland)*, vol. 16, no. 11, pp. 1–44, 2016, doi: 10.3390/s16111805.
- [24] O. A. Sensor, *Advanced Space Optical Attitude Sensor*. 2018.
- [25] V. M. N. Passaro, A. Cuccovillo, L. Vaiani, M. De Carlo, and C. E. Campanella, “Gyroscope technology and applications: A review in the industrial perspective,” *Sensors (Switzerland)*, vol. 17, no. 10, 2017, doi: 10.3390/s17102284.
- [26] C. Hsu, C. Hsu, C. Chang, and C. Lin, “A practical guide to support vector classification,” 2010, Accessed: Feb. 02, 2019. [Online]. Available: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.224.4115>.
- [27] V. V. CORINNA CORTES, “Support-Vector Networks,” *IEEE Expert. Syst. their Appl.*, vol. 7, no. 5, pp. 63–72, 1992, doi: 10.1109/64.163674.
- [28] N. S. Altman, “An introduction to kernel and nearest-neighbor nonparametric regression,” *Am. Stat.*, vol. 46, no. 3, pp. 175–185, 1992, doi: 10.1080/00031305.1992.10475879.
- [29] S. Agarwal, *Data mining: Data mining concepts and techniques*. 2014.

- [30] I. H. Witten, *Data Mining (Fourth Edition)*. 2017.
- [31] H. Kubota, M. Takeshi, and H. Saito, "3D head pose tracking using a particle filter with nose template matching," *Electron. Commun. Japan*, vol. 94, no. 1, pp. 34–42, Jan. 2011, doi: 10.1002/ecj.10268.
- [32] W. Y. Chou, C. H. Yang, H. C. Tasi, Y. C. Lin, C. F. Chuang, and K. H. Chen, "Driver distraction recognition based on dual compass motion sensing," *2014 17th IEEE Int. Conf. Intell. Transp. Syst. ITSC 2014*, pp. 1375–1380, 2014, doi: 10.1109/ITSC.2014.6957879.
- [33] F. Vicente, Z. Huang, X. Xiong, F. De la Torre, W. Zhang, and D. Levi, "Driver Gaze Tracking and Eyes Off the Road Detection System," *IEEE Trans. Intell. Transp. Syst.*, vol. 16, no. 4, pp. 2014–2027, Aug. 2015, doi: 10.1109/TITS.2015.2396031.
- [34] T. Bär, J. F. Reuter, and J. M. Zöllner, "Driver head pose and gaze estimation based on multi-template ICP 3-D point cloud alignment," *IEEE Conf. Intell. Transp. Syst. Proceedings, ITSC*, pp. 1797–1802, 2012, doi: 10.1109/ITSC.2012.6338678.
- [35] S. Bole, C. Fournier, C. Lavergne, G. Druart, and T. Lépine, "Driver head pose tracking with thermal camera," *Infrared Sensors, Devices, Appl. VI*, vol. 9974, p. 99740P, 2016, doi: 10.1117/12.2237723.
- [36] K. Torkkola, N. Massey, and C. Wood, "Driver inattention detection through intelligent analysis of readily available sensors," in *Proceedings. The 7th International IEEE Conference on Intelligent Transportation Systems (IEEE Cat. No.04TH8749)*, 2004, pp. 326–331, doi: 10.1109/ITSC.2004.1398919.
- [37] G. A. Pelaez C., F. Garcia, A. De La Escalera, and J. M. Armingol, "Driver monitoring based on low-cost 3-D sensors," *IEEE Trans. Intell. Transp. Syst.*, vol. 15, no. 4, pp. 1855–1860, 2014, doi: 10.1109/TITS.2014.2332613.
- [38] W. J. Won, M.-H. Kim, and J.-W. Son, "Driver's Head Detection Model in Color Image for Driver's Status Monitoring," in *2008 11th International IEEE Conference on Intelligent Transportation Systems*, Oct. 2008, pp. 1161–1166, doi:

- 10.1109/ITSC.2008.4732666.
- [39] H. Pose, "Suganumal Fujiwaral," no. 1, pp. 2834–2839, 2006.
- [40] K. S. Huang, M. M. Trivedi, and T. Gandhi, "Driver's view and vehicle surround estimation using omnidirectional video stream," in *IEEE IV2003 Intelligent Vehicles Symposium. Proceedings (Cat. No.03TH8683)*, 2003, pp. 444–449, doi: 10.1109/IVS.2003.1212952.
- [41] A. Ghaffari, M. Rezvan, A. Khodayari, S. H. Sadati, and A. Vahidi-Shams, "Driver's head pose estimation using a hierarchical classification on an effective feature space," *Proc. Inst. Mech. Eng. Part D J. Automob. Eng.*, vol. 226, no. 9, pp. 1233–1242, 2012, doi: 10.1177/0954407012441882.
- [42] M. R. Othman, Z. Zhang, T. Imamura, and T. Miyake, "A novel method for driver inattention detection using driver operation signals," *Int. J. Innov. Comput. Inf. Control*, vol. 8, no. 4, pp. 2625–2636, 2012.
- [43] S. Noridomi *et al.*, "Driving behavior analysis using vision-based head pose estimation for enhanced communication among traffic participants," in *2013 International Conference on Connected Vehicles and Expo (ICCVE)*, Dec. 2013, pp. 26–31, doi: 10.1109/ICCVE.2013.6799764.
- [44] L. Yu, X. Sun, and K. Zhang, "Driving Distraction Analysis by ECG Signals: An Entropy Analysis," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 6775 LNCS, 2011, pp. 258–264.
- [45] C. Yan, F. Coenen, and B. Zhang, "Driving posture recognition by convolutional neural networks," *IET Comput. Vis.*, vol. 10, no. 2, pp. 103–114, 2016, doi: 10.1049/iet-cvi.2015.0175.
- [46] H. S. Almahasneh, N. Kamel, A. S. Malik, N. Wlater, and Weng Tink Chooi, "EEG based driver cognitive distraction assessment," in *2014 5th International Conference on Intelligent and Advanced Systems (ICIAS)*, Jun. 2014, pp. 1–4, doi:

10.1109/ICIAS.2014.6869460.

- [47] D. Slieter, M. Gebhard, and P. Levi, "Evaluation of robust pose estimation methods within automotive environments," in *2012 IEEE International Conference on Vehicular Electronics and Safety (ICVES 2012)*, Jul. 2012, pp. 241–246, doi: 10.1109/ICVES.2012.6294304.
- [48] L. Zhang, D. Zhang, Y. Su, and C. Wang, "Head pose estimation based on feature extraction, fuzzy C-means and neural network for driver assistance system," in *11th IEEE International Conference on Control & Automation (ICCA)*, Jun. 2014, pp. 677–682, doi: 10.1109/ICCA.2014.6871001.
- [49] E. Murphy-Chutorian, A. Doshi, and M. M. Trivedi, "Head Pose Estimation for Driver Assistance Systems: A Robust Algorithm and Experimental Evaluation," in *2007 IEEE Intelligent Transportation Systems Conference*, Sep. 2007, pp. 709–714, doi: 10.1109/ITSC.2007.4357803.
- [50] Y. Zhu and K. Fujimura, "Head pose estimation for driver monitoring," *IEEE Intell. Veh. Symp. Proc.*, pp. 501–506, 2004, doi: 10.1109/ivs.2004.1336434.
- [51] X. Zhang, N. Zheng, F. Mu, and Y. He, "Head pose estimation using isophote features for driver assistance systems," *IEEE Intell. Veh. Symp. Proc.*, pp. 568–572, 2009, doi: 10.1109/IVS.2009.5164340.
- [52] C.-F. Chuang, C.-H. Yang, and Y.-H. Lin, "HMM-based driving behavior recognition for in-car control service," in *2015 IEEE International Conference on Consumer Electronics - Taiwan*, Jun. 2015, pp. 258–259, doi: 10.1109/ICCE-TW.2015.7216886.
- [53] Y. Dong, Z. Hu, Y. Zhou, K. Uchimura, and N. Murayama, "A robust and efficient face tracker for driver inattention monitoring system," *Proc. World Congr. Intell. Control Autom.*, no. 1, pp. 1212–1217, 2011, doi: 10.1109/WCICA.2011.5970709.
- [54] E. Murphy-Chutorian and M. M. Trivedi, "HyHOPE: Hybrid Head Orientation and Position Estimation for vision-based driver head tracking," in *2008 IEEE Intelligent Vehicles Symposium*, Jun. 2008, pp. 512–517, doi: 10.1109/IVS.2008.4621320.

- [55] K. Yuen, S. Martin, and M. M. Trivedi, "Looking at faces in a vehicle: A deep CNN based approach and evaluation," in *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*, Nov. 2016, pp. 649–654, doi: 10.1109/ITSC.2016.7795622.
- [56] S. Martin, A. Tawari, E. Murphy-Chutorian, S. Y. Cheng, and M. Trivedi, "On the design and evaluation of robust head pose for visual user interfaces: Algorithms, databases, and comparisons," *AutomotiveUI 2012 - 4th Int. Conf. Automot. User Interfaces Interact. Veh. Appl. In-cooperation with ACM SIGCHI - Proc.*, pp. 149–154, 2012, doi: 10.1145/2390256.2390281.
- [57] X. Liu, Y. Zhu, and K. Fujimura, "Real-time pose classification for driver monitoring," *IEEE Conf. Intell. Transp. Syst. Proceedings, ITSC*, vol. 2002-Janua, no. September, pp. 174–178, 2002, doi: 10.1109/ITSC.2002.1041209.
- [58] C. H. Zhao, B. L. Zhang, J. He, and J. Lian, "Recognition of driving postures by contourlet transform and random forests," *IET Intell. Transp. Syst.*, vol. 6, no. 2, pp. 161–168, 2012, doi: 10.1049/jet-its.2011.0116.
- [59] A. Tawari and M. M. Trivedi, "Robust and continuous estimation of driver gaze zone by dynamic analysis of multiple face videos," in *2014 IEEE Intelligent Vehicles Symposium Proceedings*, Jun. 2014, no. Iv, pp. 344–349, doi: 10.1109/IVS.2014.6856607.
- [60] M. Hoffken, E. Tarayan, U. Kresel, and K. Dietmayer, "Stereo vision-based driver head pose estimation," *IEEE Intell. Veh. Symp. Proc.*, no. Iv, pp. 253–260, 2014, doi: 10.1109/IVS.2014.6856578.
- [61] W. Wang, X. Zhang, Y. Wen, and F. Wang, "Study of cognitive distraction detection based on GMA analysis," in *2016 IEEE International Conference on Vehicular Electronics and Safety (ICVES)*, Jul. 2016, pp. 1–6, doi: 10.1109/ICVES.2016.7548175.
- [62] N. Ziraknejad, P. D. Lawrence, and D. P. Romilly, "The effect of time-of-flight camera integration time on vehicle driver head pose tracking accuracy," *2012 IEEE Int. Conf.*

- Veh. Electron. Safety, ICVES 2012*, pp. 247–254, 2012, doi: 10.1109/ICVES.2012.6294298.
- [63] N. Hernández, P. Jiménez, L. M. Bergasa, B. Delgado, and M. Sevillano, “Vision-based distraction analysis tested on a realistic driving simulator,” *IEEE Conf. Intell. Transp. Syst. Proceedings, ITSC*, pp. 895–902, 2010, doi: 10.1109/ITSC.2010.5625006.
- [64] M. Breidt, H. H. Bülthoff, and C. Curio, “Accurate 3D head pose estimation under real-world driving conditions: A pilot study,” *IEEE Conf. Intell. Transp. Syst. Proceedings, ITSC*, pp. 1261–1268, 2016, doi: 10.1109/ITSC.2016.7795719.
- [65] F. Rohit, V. Kulathumani, R. Kavi, I. Elwarfalli, V. Kecojevic, and A. Nimbarte, “Real-time drowsiness detection using wearable, lightweight brain sensing headbands,” *IET Intell. Transp. Syst.*, vol. 11, no. 5, pp. 255–263, Jun. 2017, doi: 10.1049/iet-its.2016.0183.
- [66] I. Takahashi and K. Yokoyama, “Development of a feedback stimulation for drowsy driver using heartbeat rhythms,” *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, pp. 4153–4158, 2011, doi: 10.1109/IEMBS.2011.6091031.
- [67] E. Abe, K. Fujiwara, T. Hiraoka, T. Yamakawa, and M. Kano, “Development of drowsy driving accident prediction by heart rate variability analysis,” in *Signal and Information Processing Association Annual Summit and Conference (APSIPA), 2014 Asia-Pacific*, Dec. 2014, pp. 1–4, doi: 10.1109/APSIPA.2014.7041787.
- [68] A. Sahayadhas, K. Sundaraj, M. Murugappan, and R. Palaniappan, “Physiological signal based detection of driver hypovigilance using higher order spectra,” *Expert Syst. Appl.*, vol. 42, no. 22, pp. 8669–8677, Dec. 2015, doi: 10.1016/j.eswa.2015.07.021.
- [69] B. Roman, S. Pavel, P. Miroslav, V. Petr, and P. Lubomír, “Fatigue Indicators of Drowsy Drivers Based on Analysis of Physiological Signals,” in *ISMDA 2001. Lecture Notes in Computer Science*, vol. 2199, 2001, pp. 62–69.

- [70] J. H. Yang and H. Bin Jeong, "Validity Analysis of Vehicle and Physiological Data for Detecting Driver Drowsiness, Distraction, and Workload," in *2015 IEEE International Conference on Systems, Man, and Cybernetics*, Oct. 2015, pp. 1238–1243, doi: 10.1109/SMC.2015.221.
- [71] G. Sun, Y. Jin, Z. Li, F. Zhang, and L. Jia, "A vision-based head status judging algorithm for driving fatigue detection system," *Adv. Transp. Stud.*, vol. 2015, no. 37, pp. 51–64, 2015, doi: 10.4399/978885488868505.
- [72] J. X. Liu and M. K. Ko, "Detection of driver's low vigilance using vehicle steering information and facial inattention features," *20th ITS World Congr. Tokyo 2013*, no. 6, pp. 1–10, 2013.
- [73] N. Alioua, A. Amine, A. Rogozan, A. Bensrhair, and M. Rziza, "Driver head pose estimation using efficient descriptor fusion," *EURASIP J. Image Video Process.*, vol. 2016, no. 1, p. 2, Dec. 2016, doi: 10.1186/s13640-016-0103-z.
- [74] N. Rodríguez-Ibáñez, M. A. García-González, M. Fernández-Chimeno, and J. Ramos-Castro, "Drowsiness detection by thoracic effort signal analysis in real driving environments.," *Conf. Proc. ... Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. IEEE Eng. Med. Biol. Soc. Annu. Conf.*, vol. 2011, pp. 6055–8, Aug. 2011, doi: 10.1109/IEMBS.2011.6091496.
- [75] M. Ito, M. Fukumi, and K. Sato, "Analysis of safety verification behavior and classification of driver's head posture," in *2013 IEEE International Conference on Mechatronics and Automation*, Aug. 2013, pp. 884–889, doi: 10.1109/ICMA.2013.6618032.
- [76] H. Park, S. Oh, and M. Hahn, "Drowsy driving detection based on human pulse wave by photoplethysmography signal processing," in *Proceedings of the 3rd International Universal Communication Symposium on - IUCS '09*, 2009, no. 3, p. 89, doi: 10.1145/1667780.1667798.
- [77] D. Lee, S. Oh, S. Heo, and M. Hahn, "Drowsy Driving Detection Based on the Driver's

- Head Movement using Infrared Sensors,” in *2008 Second International Symposium on Universal Communication*, Dec. 2008, pp. 231–236, doi: 10.1109/ISUC.2008.76.
- [78] D. M. Morris, J. J. Pilcher, and F. S. Switzer III, “Lane heading difference: An innovative model for drowsy driving detection using retrospective analysis around curves,” *Accid. Anal. Prev.*, vol. 80, pp. 117–124, Jul. 2015, doi: 10.1016/j.aap.2015.04.007.
- [79] L. P. Morency, J. Whitehill, and J. Movellan, “Monocular head pose estimation using generalized adaptive view-based appearance model,” *Image Vis. Comput.*, vol. 28, no. 5, pp. 754–761, 2010, doi: 10.1016/j.imavis.2009.08.004.
- [80] J. Wang, S. Sun, S. Fang, T. Fu, and J. Stipanovic, “Predicting drowsy driving in real-time situations: Using an advanced driving simulator, accelerated failure time model, and virtual location-based services,” *Accid. Anal. Prev.*, vol. 99, pp. 321–329, Feb. 2017, doi: 10.1016/j.aap.2016.12.014.
- [81] H. Matsuo and A. Khiat, “Prediction of Drowsy Driving by Monitoring Driver’s Behavior Hardware configuration,” in *International Conference on Pattern Recognition*, 2012, pp. 3390–3393, doi: 10.14923/transinfj.2014JDP7107.
- [82] Q. Ji and X. Yang, “Real-time eye, gaze, and face pose tracking for monitoring driver vigilance,” *Real-Time Imaging*, vol. 8, no. 5, pp. 357–377, 2002, doi: 10.1006/rtim.2002.0279.
- [83] I.-H. Choi, C.-H. Jeong, and Y.-G. Kim, “Robust Facial States Estimation against Occlusion and Inference of Driver’s Drowsiness Using Hidden Markov Model,” in *Lecture Notes in Electrical Engineering*, vol. 352, no. August, J. J. Park, H.-C. Chao, H. Arabnia, and N. Y. Yen, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2015, pp. 45–51.
- [84] J. Wu and M. M. Trivedi, “Visual modules for head gesture analysis in intelligent vehicle systems,” *IEEE Intell. Veh. Symp. Proc.*, pp. 13–18, 2006, doi: 10.1109/ivs.2006.1689598.

- [85] K. Liu, Y. P. Luo, G. Tei, and S. Y. Yang, "Attention recognition of drivers based on head pose estimation," *2008 IEEE Veh. Power Propuls. Conf. VPPC 2008*, pp. 1–5, 2008, doi: 10.1109/VPPC.2008.4677536.
- [86] J. Paone, D. Bolme, R. Ferrell, D. Aykac, and T. Karnowski, "J. Paone, D. Bolme, R. Ferrell," no. Iv, pp. 0–5, 2015.
- [87] C.-T. Lin, L.-W. Ko, and T.-K. Shen, "Computational intelligent brain computer interaction and its applications on driving cognition," *IEEE Comput. Intell. Mag.*, vol. 4, no. 4, pp. 32–46, Nov. 2009, doi: 10.1109/MCI.2009.934559.
- [88] M. R. Othmvan, Z. Zhang, T. Akiduki, H. Suzuki, T. Imamura, and T. Miyake, "Development of a driver inattention detection system using dynamic relational network," *Int. J. Innov. Comput. Inf. Control*, vol. 10, no. 3, pp. 1189–1205, 2014.
- [89] "Weka 3: Data Mining Software in Java 2017," p. 3, 2016.
- [90] J. M. Ramirez, M. D. Rodriguez, A. G. Andrade, L. A. Castro, J. Beltran, and J. S. Armenta, "Inferring drivers' visual focus attention through head-mounted inertial sensors," *IEEE Access*, vol. 7, pp. 185422–185432, 2019, doi: 10.1109/ACCESS.2019.2960567.
- [91] J. S. Armenta, A. G. Andrade, and M. D. Rodriguez, "An Intelligent Multi-Sourced Sensing System to Study Driver's Visual Behaviors," *IEEE Sens. J.*, vol. 21, no. 10, pp. 12295–12305, 2021, doi: 10.1109/JSEN.2021.3064080.
- [92] H. K. Jang, H. Han, and S. W. Yoon, "Comprehensive Monitoring of Bad Head and Shoulder Postures by Wearable Magnetic Sensors and Deep Learning," *IEEE Sens. J.*, vol. 20, no. 22, pp. 13768–13775, 2020, doi: 10.1109/JSEN.2020.3004562.
- [93] "Yost Labs Inc . [Online]. Available: [https:// https://yostlabs.com/.](https://yostlabs.com/)"

Apéndice A

Una de las evaluaciones realizadas para conocer el desempeño de las técnicas de inferencia con el objetivo de identificar cuál de los sensores es el más adecuado para determinar el foco de atención de los conductores, se realizaron pruebas de todos los sensores y todas sus combinaciones posibles, es decir, los datos fueron utilizados en forma independiente y en todas sus combinaciones para entrenar las máquinas de inferencia.

Como se observa en la figura 26 los resultados demuestran que el uso de los 3 sensores nos da los mejores porcentajes de clasificación

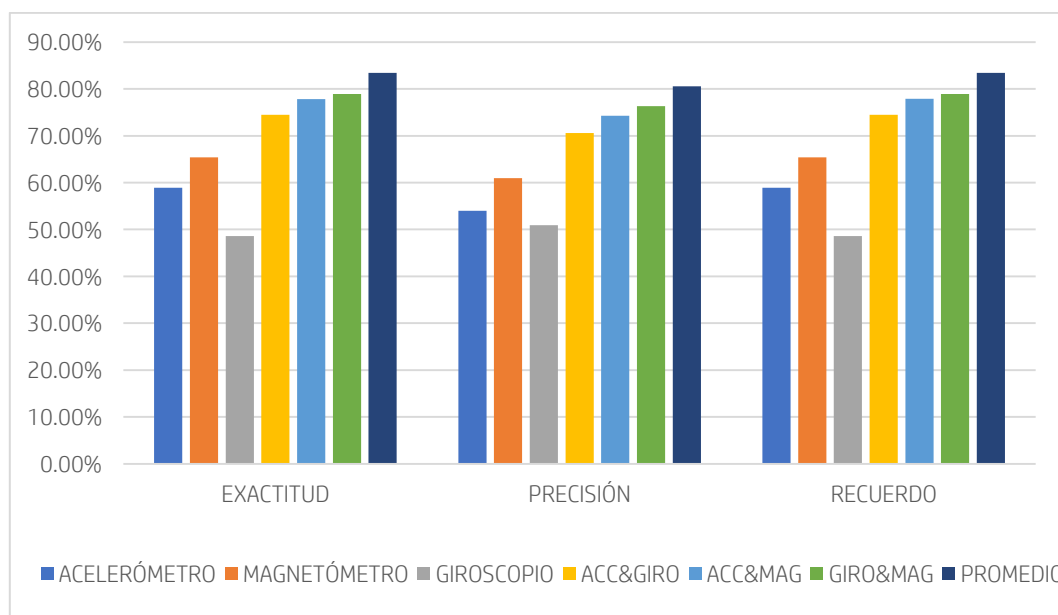


Figura 26 Sensores y sus combinaciones.

Además de identificar la combinación de sensores más adecuada para la inferencia del foco de atención, esto podría servir para identificar como afecta al rendimiento de la batería del dispositivo el uso de cada uno de los sensores y sus combinaciones, lo que nos

podría llevar a, bajo ciertas circunstancias decidir que sensor es el más adecuado de utilizar.

Otra de las comparaciones que se realizaron fue para identificar la cantidad de tuplas necesarias para obtener un buen rendimiento por parte de las máquinas de inferencia, por ello se evaluó el 20%, 40%, 60%, 80% y 100% del total de los datos, para evaluar k-NN, obteniendo el resultado que se muestra en la figura 27.

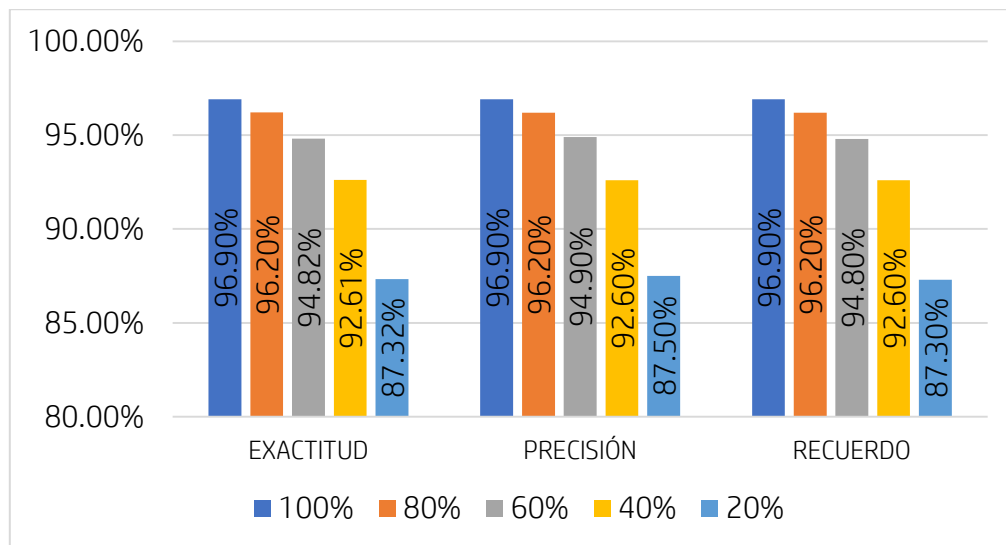


Figura 27 Porcentajes evaluados con k-NN.

Apéndice B

Se dice que “las manos en el volante y los ojos en el camino”, es la forma ideal de realizar una conducción, sin embargo, debido a falta de atención o a la inatención durante el proceso de conducción se ocasionan accidentes o casi accidentes, y como medida de prevención en el sentido de mantener informados a los demás conductores de una vialidad, se propone la utilización de un protocolo de comunicación entre vehículos, conocida como comunicación “vehicle-to-vehicle v2v”.

Se exploró la comunicación entre vehículos utilizando dispositivos de comunicación LoRa los cuales son una tecnología de radiofrecuencia que proporciona comunicación de espectro extendido de rango ultra largo y alta inmunidad a interferencias mientras minimiza el consumo de corriente. Los dispositivos LoRa utilizan un transceptor SX1276/77/78/79 que es una tecnología patentada por Semtech.

Se construyó un prototipo utilizando LoRa, aprovechando la posibilidad de utilizar la red de área amplia de baja potencia (LPWAN) la cual ofrece varias características que la hacen adecuada para el dominio de esta aplicación. Además, se propone un protocolo de comunicación para permitir la cobertura de los usuarios. Los requerimientos del sistema son los siguientes:

Basándonos en el caso de un accidente, en el cual algún vehículo sufre algún percance que no le permita continuar en movimiento y sea un factor de riesgo para los demás vehículos, éste debería de comenzar a radiar información que le permita a los vehículos que se aproximan al lugar del accidentes estar prevenidos, es decir, la información radiada por el vehículo accidentado, tendría como principal motivo, activar una alarma en los vehículos que se aproximan con el objetivo de disminuir la velocidad si son autónomos o de notificar al conductor de que se encuentra próximo a alguna situación que requiera de su máxima atención.

Debido a la complejidad de la implementación de un dispositivo de radiocomunicación y más que nada a la implementación de la infraestructura requerida para llevar a cabo la evaluación del protocolo de comunicación, se realizó un experimento con el cual, aún que, con un escenario diferente, pero bajo la misma circunstancia, se logra evaluar el funcionamiento de la transmisión de la información entre dos dispositivos.

Debido a esta situación se plantea un protocolo de comunicación que utiliza a dispositivos LoRa como medios de comunicación entre vehículos. Este protocolo fue desarrollado para una red de vehículos que se encargan de notificar al conductor, un mensaje enviado por el vehículo involucrado en algún tipo de accidente o casi accidente.

Se parte de que se tiene un Transmisor (Tx), que se encarga de radiar la información, y de que existen n receptores (Rx's) que recibirán la información para desplegar el mensaje ya sea en pantalla o mediante un indicador al conductor. Es por esto y con la característica de que los conductores de estos vehículos y sin importar su movilidad dentro de la ciudad, existirán aquellas situaciones en que algunos de estos vehículos se encuentren fuera de la cobertura del Tx, debido a esto se propone el siguiente protocolo:

- I. Todos los vehículos Rx's tendrán un identificador, es decir un número que identifique a cada uno de ellos.
- II. Solo existe un Tx que se encarga de comenzar la difusión del mensaje (que será el vehículo que se encuentre involucrado en algún accidente o casi accidente).
- III. Una vez que todos los Rx's reciban el mensaje se convertirán en Tx's para difundir el mensaje.
- IV. Todos los sujetos que conforman la red de propagación tienen la característica de comparar el mensaje recibido con uno previo.
- V. Tanto en el Tx como en los Rx's que ahora son TX's, si no existe un mensaje previo con las mismas características que el actual, se le dará difusión al mensaje recibido.

VI. Aquellos Rx's que realizan la comparación del mensaje previo con el actual y resulta ser el mismo mensaje, no se convertirán en TX's.

En el siguiente diagrama se puede observar la topología del protocolo de comunicación, en el cual dentro del círculo de cobertura del Tx se encuentran 8 usuarios, de los cuales, todos se convierten en TX's, pero debido a la condición de comparación del mensaje, la segunda vez que reciben el mensaje y este es igual al previo, ya no lo reenvía. Dentro del segundo círculo color naranja, se encuentran 4 usuarios, los cuales, después de recibir el mensaje se convierten en Tx's, y reenvían el mensaje, y por último fuera de todos los círculos, se encuentran solamente dos usuarios, los cuales se pueden clasificar como usuarios finales.

Como se observa en la figura 28, se puede identificar todas las características mencionadas anteriormente de este protocolo de comunicación. Con la ayuda de este protocolo de comunicación se pretende informar a todos los usuarios próximos a un accidente tratando de prevenir la causa de algún otro accidente derivado de éste.

Cabe resaltar que como se mencionó anteriormente, el vehículo o los vehículos involucrados en el accidente, son los que se identifican en la figura 28 como el GATEWAY, el cuál será el encargado de comenzar la transmisión de este protocolo de comunicación.

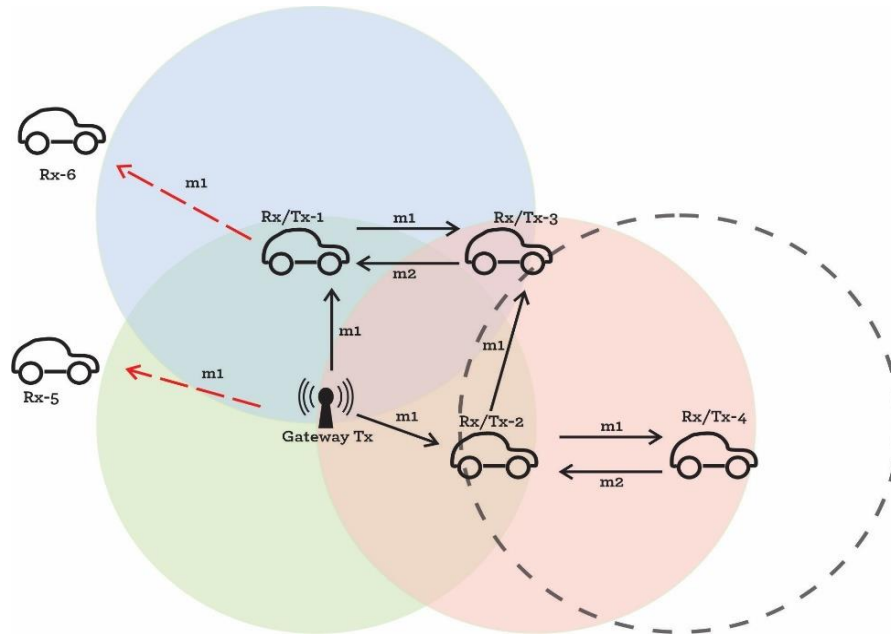


Figura 28 Protocolo basado en difusión para el paso de mensajes un escenario que describe cómo se propaga un mensaje, el diagrama de flujo b ilustra los pasos del protocolo.

Como complemento de este protocolo de comunicación, y para dejar en claro el funcionamiento del mismo, la figura 29 muestra el diagrama de flujo del protocolo, en el cual se contemplan todas las posibilidades que puede cumplir uno de los dispositivos que se encuentren dentro del área de cobertura.

Como se muestra en las figuras 29 y 30, se realizó la evaluación de la potencia de recepción del dispositivo, mediante un análisis preliminar, en el cual se instaló un dispositivo Gateway bajo dos condiciones. La primera de ellas fue sin línea de vista, es decir, el Gateway fue colocado en el interior del laboratorio; y en la segunda, el Gateway fue colocado en el exterior del laboratorio.

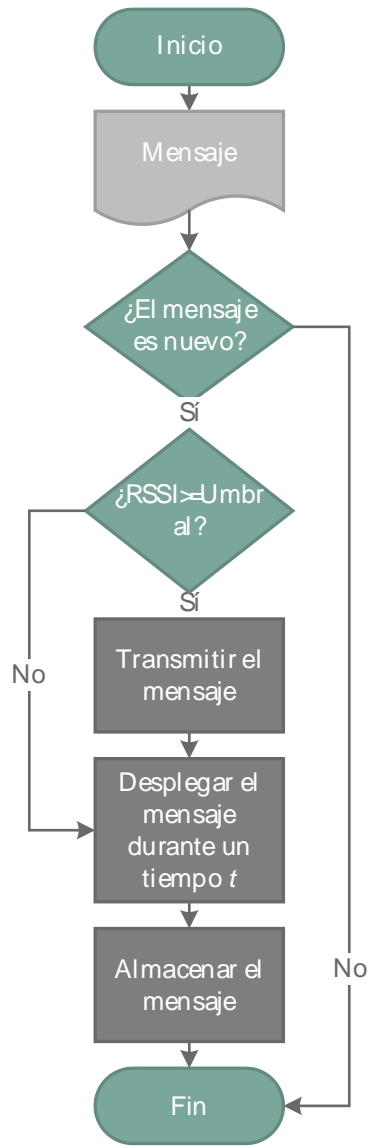


Figura 29 Diagrama de flujo.

Además, nos dimos a la tarea de evaluar el desempeño de los módulos propuestos para la implementación esta comunicación LoRa, la cual consistió en colocar uno de estos dispositivos como Gateway, y con otro dispositivo similar, realizar un recorrido en línea recta, capturando la información de la potencia de recepción (RSSI) en dB's. con línea de vista en el caso de la figura 30 y sin línea de vista en el caso de la figura 29.

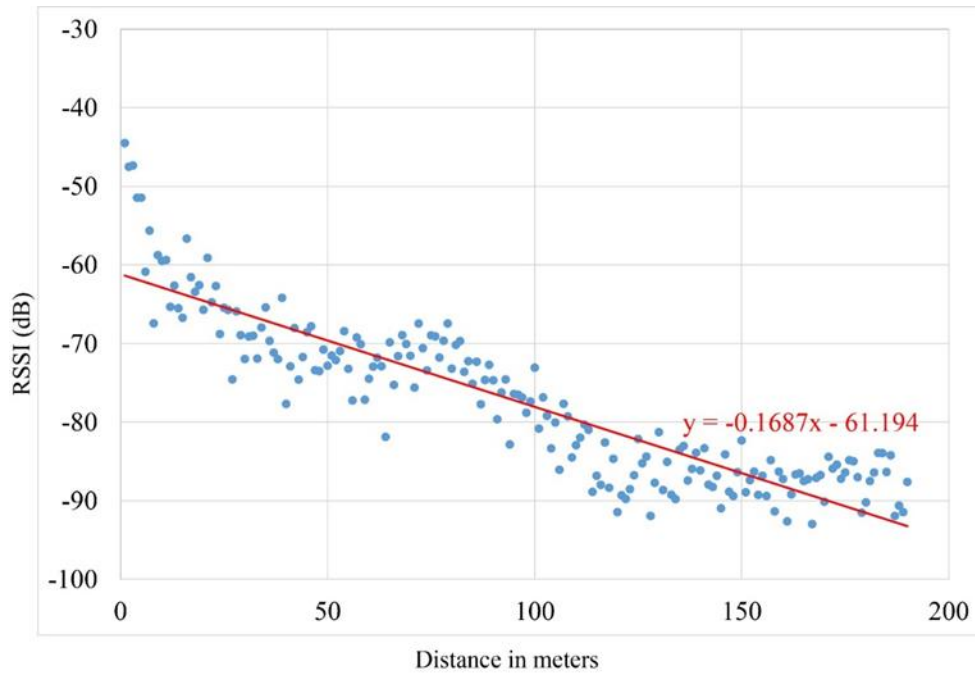


Figura 30 RSSI en interiores.

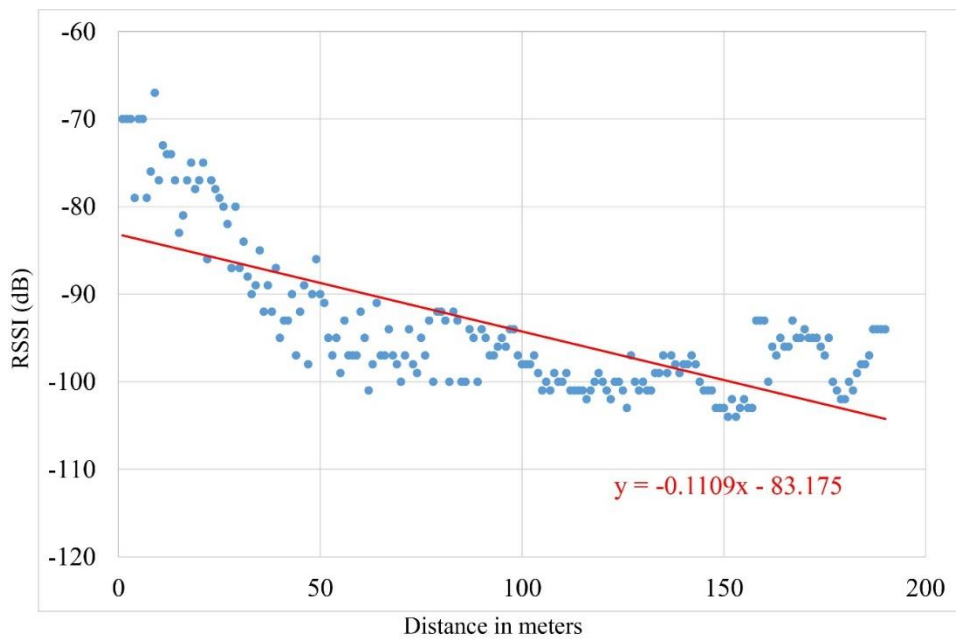


Figura 31 RSSI en exteriores.