

**Estudio sobre componentes de vehículos
autónomos y semiautónomos. Propuesta de
protocolo de inspección técnica**

Trabajo Fin de Grado

Grado en Ingeniería Eléctrica Industrial y Automática

Autor: Adam Milan Kosztinski
Tutor: Evelio José González González



**Escuela Superior
de Ingeniería y Tecnología**
Universidad de La Laguna



Contenido

1. ABSTRACT	3
2. RESUMEN	3
3. INTRODUCCIÓN	4
3.1 Consideraciones iniciales:.....	4
3.2 Objetivos:.....	8
3.3 Métodos y Estructura	8
4. FUNCIONAMIENTO DEL SISTEMA AUTÓNOMO.....	9
5. COMPONENTES INDIVIDUALES.....	13
5.1 Sensores	13
5.1.1 Cámara	13
5.1.2 LiDAR:	17
5.1.3 Radar:.....	24
5.2 Localización y mapeo:	27
5.2.1 GPS:	28
5.2.2 CP para comunicación vehículo-todo (V2X):	28
5.2.3 Unidad de medición inercial (IMU):	32
5.2.4 Localización y mapeo simultáneos (SLAM):.....	32
5.2.5 Structure from motion (SfM):	35
5.3 Unidad computacional (Hardware):.....	36
5.4 Drive by wire (Conexiones):.....	38
6. REQUISITOS PARA INSTALACIONES	38
6.1 Plataforma de sujeción de sensores:.....	38
6.2 Unidad computacional:	38
6.3 Cámaras:	39
6.4 LiDAR:	39
6.5 Radar:.....	39
6.6 Cables Ethernet:.....	40
6.7 Gafas de protección:.....	40
6.8 Cinta omnidireccional:.....	40
7. PRESUPUESTO DE INSTALACIÓN	40
8. PROCEDIMIENTO DE INSPECCIÓN	41
7.1 Cámaras	42
7.2 LiDAR	44
7.3 Radar.....	46
7.4 GPS.....	48
7.5 Comunicación vehículo-todo (V2X).....	49
7.6 Unidad de medición inercial (IMU).....	51
7.7 Localización y mapeo simultáneos (SLAM).....	52
7.8 Structure from motion (SfM).....	53
7.9 Unidad computacional (Hardware)	54



7.10 Drive by wire (Conexiones)	55
9. CONCLUSIONES	56
10. APÉNDICE.....	57
Tabla 4: “Causas de fallos en las cámaras”	57
Tabla 17 “Fallos en el Radar”	59
Tabla 23: “Evolución de soluciones con sensores visuales”	60
11. FUENTES BIBLIOGRÁFICAS.....	62



1. ABSTRACT

Autonomous vehicles are systems that takes partial or complete control of the longitudinal and lateral movement of a motor vehicle to follow a predetermined path plotted with the intention of arriving to where the passenger requested, even if said passenger is not in the vehicle. This kind of change in the dynamic for the transport of people and goods alters the necessary rules and regulations that needs to be implemented in the traffic of today. By removing the driver from the steering wheel and placing there a preprogramed system, we can predict how they will interact with other autonomous vehicles interchanging information like no human driver can.

For this reason, the autonomous vehicles industry is an ever-expanding field for investigation with significant achievements in the last years thanks to the introduction of civilian models on the roads. Due to the proposal by the European Union of a new legislation with the objective to promote innovation, adoption and standardization of basic requirements, there is a need to revise the necessary infrastructure required to suit this future incorporation to our roads.

With this kind of promises, if they are achieved, we can expect their introduction in the coming decade with a growing need to adapt our infrastructure up to par, like we changed city layout for the advent of the car for the urban environment. We will need to adapt some aspects of our regular interactions with them like infrastructure and regular processes. Although the obvious need to adapt the road infrastructure to interconnect all these vehicles is ever present, a smaller yet still very important aspect is securing the safety of derived from said autonomous vehicles in the roads so they can operate in their intended state. For this goal we have the vehicle inspections that all motor owners need to pass so they can operate in traffic. By augmenting the capacity of our cars for self-driving we introduce more components that could fail and compromise the security for other users of the road. This new addition needs to also be inspected for defects in their own environment so all relevant defects can be discovered and repaired.

The goals of this end of degree project are to study the state of the art of the components required for an autonomous vehicle understanding its history and how they work in their respective roles and present a technical guide for vehicle inspections focused on the advanced driver assistance systems (ADAS) encompassing the necessary models, components and practices. Every component is separately examined and inspected for defects so the gravity of a possible failure can be accurately assessed. For this end, the presented decisions, propositions and requirements are informed based on scientific articles in this field.

2. RESUMEN

Los vehículos autónomos son sistemas que tienen el objetivo de controlar de manera parcial o total del movimiento longitudinal y lateral de un vehículo automotor para seguir una trayectoria predeterminada trazada con la intención de llegar a donde el pasajero haya indicado con antelación, incluyendo los casos donde dicho pasajero no esté en el vehículo mismo. Este tipo de cambio en la dinámica para el transporte de personas y mercancías altera las reglas y regulaciones que se necesitan en el tráfico de nuestra actualidad. Al quitar el conductor fuera del volante y colocar allí un sistema preprogramado, nosotros podemos predecir la forma en la este interactuará con otros vehículos autónomos utilizando el intercambio de información como ningún conductor humano sería capaz.

Las tecnologías y soluciones de vehículos autónomos es un área de investigación cada vez más relevante y empleada con avances significativos en los últimos años gracias a la introducción de modelos civiles al mercado. Gracias a la reciente propuesta de la Unión Europea de la creación de una legislación para fomentar la innovación, adopción y estandarización de requisitos básicos, se ve la necesidad de investigar la infraestructura precisa para acomodar esta nueva incorporación al tráfico.

Con este tipo de promesas, si se cumplen, podemos esperar la implementación de esto nuevo avance en la próxima década necesitando adaptar nuestra infraestructura a la par, tal como en el pasado hemos cambiado las carreteras en nuestras ciudades gracias a la llegada del coche al entorno urbano. Por ello, tendremos la necesidad de adaptar algunos aspectos de las interacciones habituales con nuestros vehículos, tal como la infraestructura y los procesos habituales que se realizan. Aunque la necesidad obvia de adaptar la infraestructura vial para interconectar todos estos vehículos está siempre presente, un aspecto menor, pero aun así muy relevante, es garantizar la seguridad de estos vehículos autónomos en las carreteras para que puedan operar en su estado predeterminado. Para este fin contamos con las inspecciones vehiculares que todos los propietarios de motores deben pasar para poder operar en el tráfico. Al aumentar la capacidad de conducción autónoma de nuestros automóviles, introducimos más componentes que podrían fallar y comprometer la seguridad de otros usuarios de la carretera. Esta nueva pieza



también debe inspeccionarse en busca de defectos en su propio entorno para que se puedan descubrir todos los defectos relevantes.

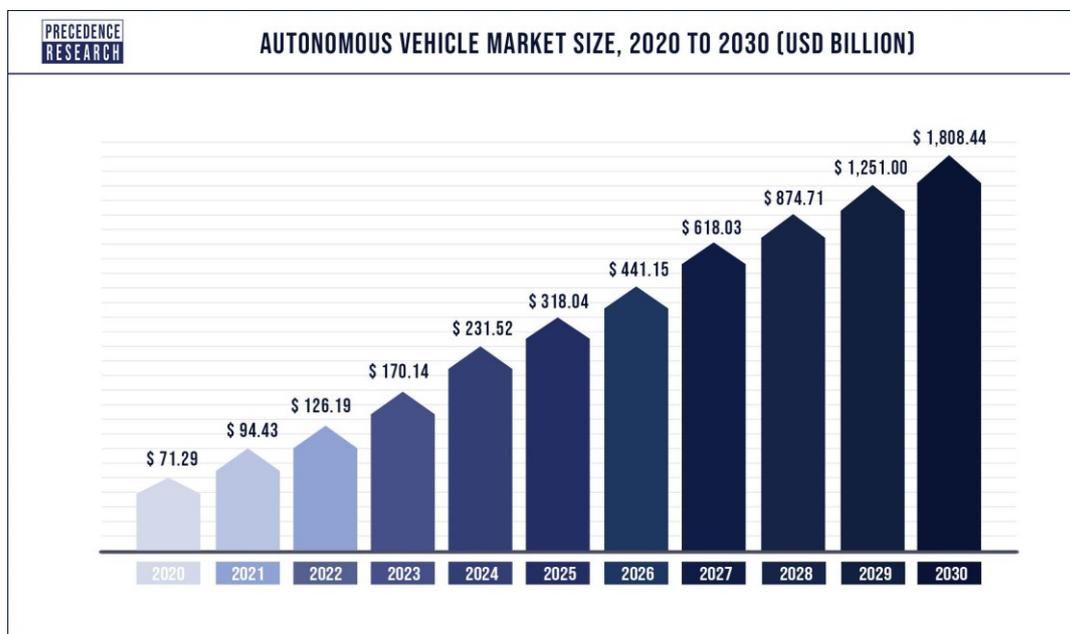
El objetivo de este TFG es el estudio del estado de arte de los componentes de un vehículo autónomo entendiendo su historia y su funcionamiento en sus respectivas funciones y propuesta de una guía técnica de inspección técnica de vehículos (ITV) enfocado a los sistemas avanzado de asistencia al conductor (*Advanced Driver Assistance System, ADAS*), incluyendo modelos, componentes y prácticas necesarias. Esto se intenta conseguir utilizando artículos científicos en el área, para apoyar las decisiones y propuestas implementadas y definir los requisitos exactos necesarios.

3. INTRODUCCIÓN

3.1 Consideraciones iniciales:

¿Cuál es el recurso más valioso que tenemos a nuestra disposición? ¿Por qué nos esforzamos para alcanzar mayor velocidad, mayor eficiencia y rendimiento en todos los aspectos de nuestra vida? Tiempo. El tiempo que invertimos en diferentes actividades y trabajos es nuestro mayor recurso, pudiendo obtener a cambio cualquier producto o servicio. Cada vez que somos capaces de aumentar el tiempo libre a nuestra disposición, alocando de manera sabia y eficiente, podemos incrementar los beneficios y recompensas que nos esperan. Por esta razón buscamos diferentes formas de obtener los mismos o mayores beneficios invirtiendo menos de este preciado recurso. Buscamos aumentar la eficiencia de la conversión.

Desde la primera invención de los humanos hemos implementado diferentes técnicas y tecnologías con el propósito de aumentar la eficiencia y tiempo disponible. Industrias para producir más productos en menos tiempo, teléfonos para comunicarse con mayor rapidez y vehículos para llegar antes a nuestro destino. Con la introducción de los vehículos autónomos podemos aprovechar el tiempo al volante para trabajar, descansar o socializar sin preocuparnos de atender a la carretera. Automatizando este proceso de nuestras vidas nos da la posibilidad de dedicar nuestra atención donde verdaderamente importa Esta tecnología, cada vez más extendida por el mundo, es el siguiente paso y un futuro tan inevitable como ha sido la implementación de los trenes y aviones. Por ello, gracias a la explosión de interés e inversiones por parte de todos los sectores de la automoción durante la última década y predicciones para el futuro (ver Gráfica 1), se espera una adopción masiva en el continente de América del Norte y Europa en la próxima década.

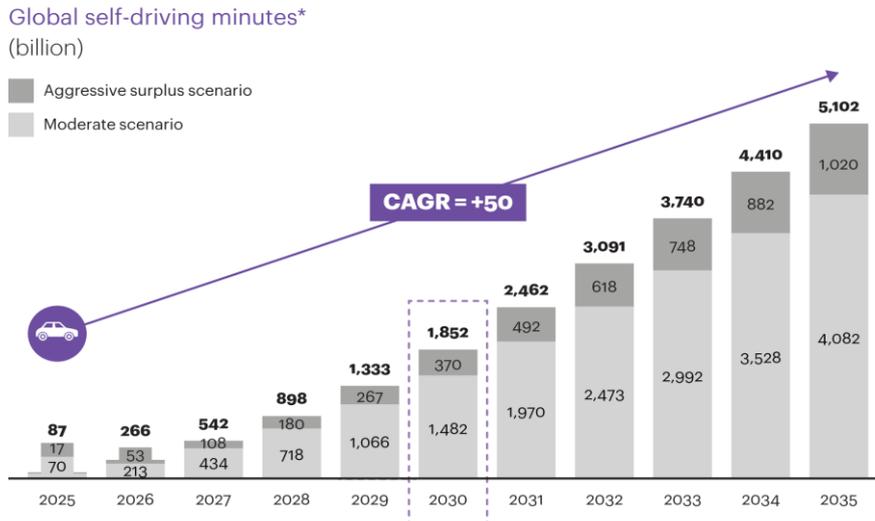


Gráfica 1: "Autonomous vehicle market" [Online]. Disponible en: <https://www.precedenceresearch.com/autonomous-vehicle-market>. [Accedido en: 3-Jun-2022].



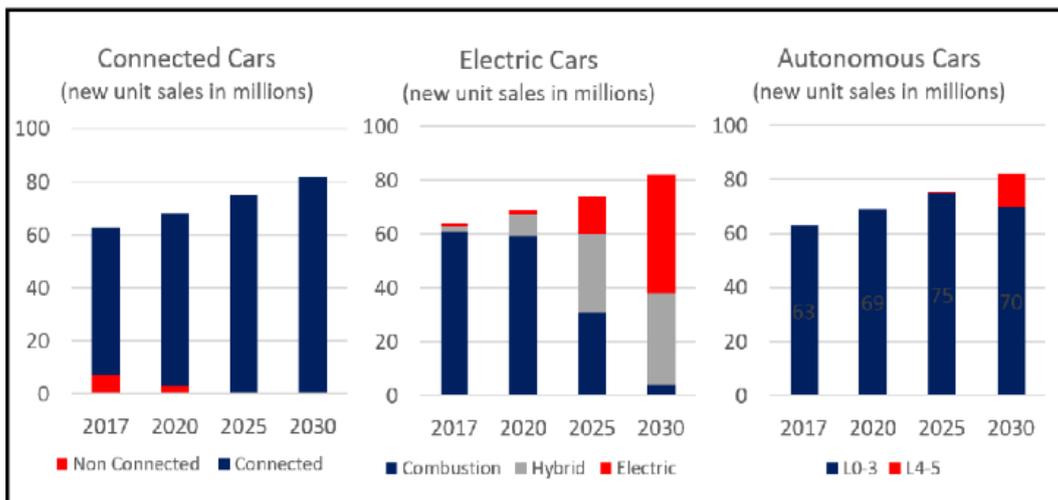
Toda esta especulación tampoco son predicciones en vano, ya que los minutos que se esperan salvar con solo esta tecnología son enormes (ver Gráfica 2). Se estima que solo en el año 2030 se salvarán 1852 billones de minutos globalmente gracias a los vehículos autónomos.

Figure 4
Self-driving will free up 1.9 trillion minutes of idle time in 2030



Gráfica 2: “How automakers can survive the self-driving era” [Online]. Disponible en: <https://www.es.kearney.com/automotive/article/a/how-automakers-can-survive-the-self-driving-era>. [Accedido en: 3-Jun-2022].

En los Estados Unidos, donde operan algunas de las empresas innovadoras en respecto a coches autónomos, se observa el aumento de ventas de vehículos para el sector civil y comercial. Solo para el año 2030 se predicen 80 millones de vehículos autónomos vendidos según un estudio en [1].



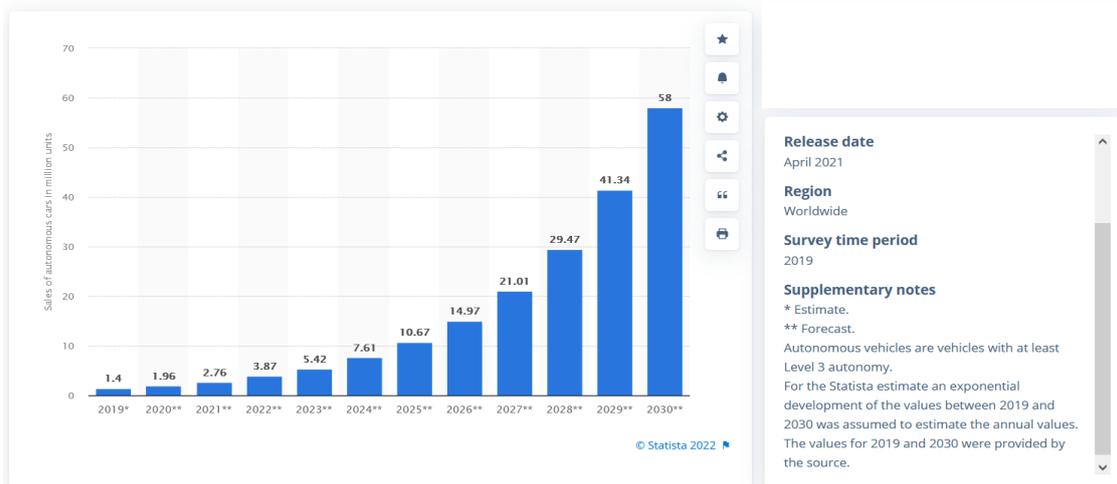
Gráfica 3: “Tendencias del mercado de coches conectados, autónomos y eléctricos de 2017 a 2030 en EE. UU., Europa y China”, fuente de [1]

También, para mostrar otra estadística del mismo tema, la predicción de 2019 para ventas globales entre el año 2019 y 2030 (Gráfica 4) atribuye 58 millones de unidades vendidas sólo en el año 2030.



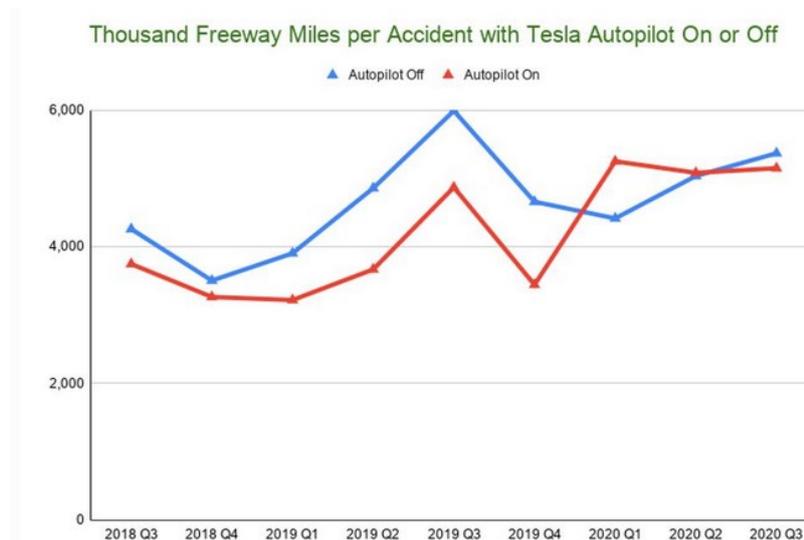
Projected sales of autonomous vehicles worldwide from 2019 to 2030

(in million units)



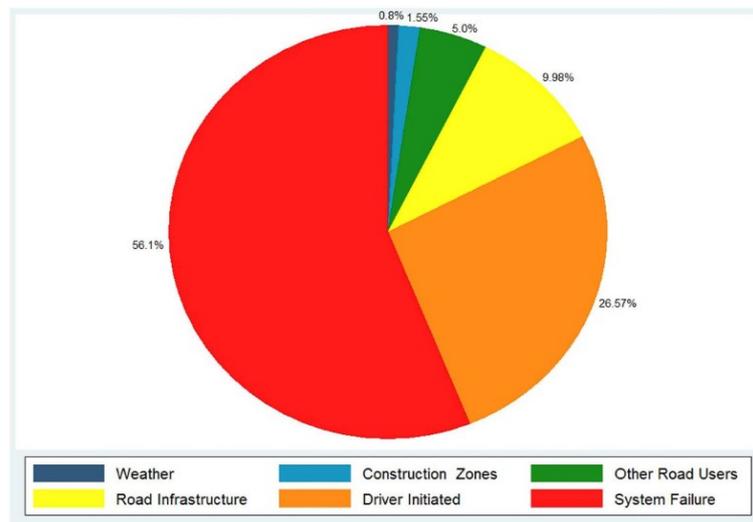
Gráfica 4: “Projected sales of autonomous vehicles worldwide from 2019 to 2030” [Online]. Disponible en: <https://www.statista.com/statistics/1230733/projected-sales-autonomous-vehicles-worldwide> [Accedido en: 3-Jun-2022].

Por otro lado, otra razón a favor de la introducción de coches con sistemas ADAS es la reducción de accidentes en las carreteras. Entre 2018 y 2020 se observa que en los vehículos Tesla, el número de accidentes es mayor (miles por milla) cuando la función de piloto automático está desactivada, salvo el caso en el primer cuatrimestre de 2020, según Forbes (Gráfica 5).



Gráfica 5: “New Tesla autopilot statistics...” [Online]. Disponible en: <https://www.forbes.com/sites/bradtempleton/2020/10/28/new-tesla-autopilot-statistics-show-its-almost-as-safe-driving-with-it-as-without/?sh=145985661794> [Accedido en: 10-Jun-2022].

Este resultado es posiblemente a causa de error humano y mayor tiempo de reacción necesario comparado con vehículos autónomos. Sin embargo, se debe tener en cuenta que antes del accidente o en situación inesperada el vehículo deberá pasar el control al conductor (disengagement) en un tiempo de respuesta razonable (entre 3 y 7 segundos). Por ello, en la actualidad todavía se necesitan conductores atentos para reducir la posibilidad de accidente. Estas desconexiones pueden ocurrir por una variedad de razones, siendo el más frecuente por fallos del sistema autónomo en el 56,1% de los casos, seguido por disengagement iniciado por el conductor a 26,57% y 9,98% gracias a causas ocasionadas por la infraestructura de la carretera. Según los datos, disengagement a causa de otros conductores (5%), zonas de construcción (1,55%) y clima (0,8%) son menores, demostrando que los sistemas utilizados son robustos para prevenir y responder por sí solo en estos 3 casos. Esta información está expuesta en la Gráfica 6 en [2].



Gráfica 7: "Razones de desconexión" [2]

De todas estas desconexiones solo algunas provocan situaciones de accidente y aún menos de ellos ocasionan daños materiales o humanos (Tabla 1 en [2]).

Table 1. Summary sheet of accidents involving autonomous vehicles.

Date	Time	Company	AV mode?	Status of AV	Status of other vehicle	Type of collision	AV's fault?	Damage to AV	Damage to other vehicle	Injuries
14/10/2014	19:27	Delphi	Yes	Stopped	Moving	Side-swipe	No	damaged fender and front bumper	NA	No
26/02/2015	AM	Google	*	Moving	Moving	Side-swipe	No	right rear quarter panel and right rear wheel	NA	No
07/04/2015	AM	Google	Yes	Moving	Moving	Rear-end	No	minimal body damage	no damage	No
27/04/2015	16:27	Google	Yes	Stopped	Moving	Side-swipe	No	no damage	no damage	No
30/05/2015	12:00	Google	Yes	Stopped	Moving	Rear-end	No	minor damage to rear sensor and bumper	no damage	No
04/06/2015	08:54	Google	Yes	Stopped	Moving	Rear-end	No	no damage	no damage	No
18/06/2015	11:15	Google	Yes	Stopped	Moving	Rear end	No	scrapes to rear bumper	scrapes to front bumper	No
01/07/2015	17:16	Google	Yes	Stopped	Moving	Rear-end	No	minor damage to rear bumper	significant damage to front end	AV's driver and passenger reported whiplash, while the other driver reported neck and back pain
20/08/2015	09:36	Google	*	Moving	Moving	Rear-end	No	minor damage to rear bumper	moderate damage to front end and was towed	AV driver reported minor back pain
02/11/2015	14:30	Google	Yes	Stopped	Moving	Rear-end	No	minor damage to rear bumper	minor damage to headlight, vehicle hood, and front bumper	No
08/01/2016	13:41	Cruise Automation	*	Moving	Stopped	Side-swipe	No	Minor damage to front right quarter panel	Minor damage to front left quarter panel	No
14/02/2016	PM	Google	Yes	Moving	Moving	Side-swipe	Yes	Damage to left front fender	No damage	No

* Indicates the autonomous mode was manually disengaged few moments prior to the accident.

Tabla 1: "Resumen de accidentes de vehículos autónomos" [2]



En la tabla anterior solo 1 de los 12 casos de accidentes es provocado por el sistema ADAS demostrado y teniendo un tiempo de respuesta de 0.84 segundos de media.

Por ello, con toda la información anteriormente expuesta se puede concluir que, en un futuro cercano, España tendrá la necesidad de aceptar esta tecnología en sus carreteras para mantenerse competitivo y progresivo en este mundo de constante cambio. Gracias a esto se puede razonar con gran certeza, que el efecto de la adopción de dichos vehículos creará la necesidad de técnicos especializados en la detección y reparación de fallos concernientes del sistema autónomo. Aunque el deber de reparación no recaerá en los hombros del estado español, la necesidad de garantizar la seguridad de las carreteras sí y por ello se recomienda la actualización del proceso por el que operan las estaciones ITV (Inspección Técnica de Vehículos) reconociendo el estado de arte presente y el camino recorrido para llegar hasta aquí. Este TFG (Trabajo Fin de Grado), no tiene el objetivo de reinventar la fórmula por el que opera todo el proceso de inspección, sino añadir los pasos necesarios para asegurar la seguridad en las carreteras aun con la introducción de este nuevo avance y exponer las tecnologías y técnicas más relevantes en la elaboración de dichos sistemas.

Como se explicará en los apartados posteriores, esta tecnología está a un paso del verdadero control autónomo, el cual se caracteriza por la falta de la necesidad de una supervisión continua por parte del conductor y por ello es capaz de cambiar y mejorar en direcciones imposibles de predecir. En el presente TFG se enfocarán, no solo los pasos técnicos y elementos a utilizar en las inspecciones de los vehículos autónomos en la actualidad, si no también crear la fundación sobre la que se implementarán las ideas del futuro y los elementos necesarios para ello, atendiendo a las soluciones más relevantes y desarrolladas. Los procesos y pasos descritos en el TFG por ello seguirán la forma aceptada de una guía de inspección de las estaciones ITV, pero añade las ideas y estructuras necesarias para su implementación en la vida real.

3.2 Objetivos:

Por ello, viendo el rápido avance de las tecnologías y soluciones implementadas por diferentes fabricantes, en los últimos años se ha observado la distribución de soluciones comerciales de vehículos autónomos para el público. Los mencionados vehículos todavía no muestran las principales características que definirían una solución completamente autónoma, pero señalan la tendencia y camino que seguirán y alcanzarán en un futuro cercano. Por consiguiente, se ve la necesidad de anticipar estos avances y proporcionar a los conductores una forma segura y fiable de realizar las inspecciones adicionales necesarias para seguir todas las normas de tráfico. Estas inspecciones complementarán las ya existentes dentro del marco de las funciones de los talleres ITV.

Así pues, en este TFG se propondrán y recomendarán las soluciones e implementaciones necesarias para las inspecciones técnicas de ITV concerniente a todos los elementos necesarios y utilizados por el sistema autónomo de un vehículo motor. Por otro lado, para contextualizar y argumentar el estado de los componentes de un vehículo autónomo en la actualidad, se explicarán también el estado del arte y evolución de dichos elementos y las soluciones ideales tanto para las inspecciones como para los vehículos a inspeccionar, utilizando datos recopilados de estudios anteriores. Estas soluciones y componentes también son explicados, exponiendo no sólo cómo funcionan, sino cómo se solucionan los problemas que surgen de estas tecnologías, profundizando en las áreas necesarias para ello.

3.3 Métodos y Estructura

La forma de realización de este trabajo se llevó a cabo mediante la recopilación de informaciones bibliográficas, artículos, documentos técnicos y sitios web relacionados con los elementos, métodos y pruebas sobre los diferentes componentes de un vehículo autónomo.

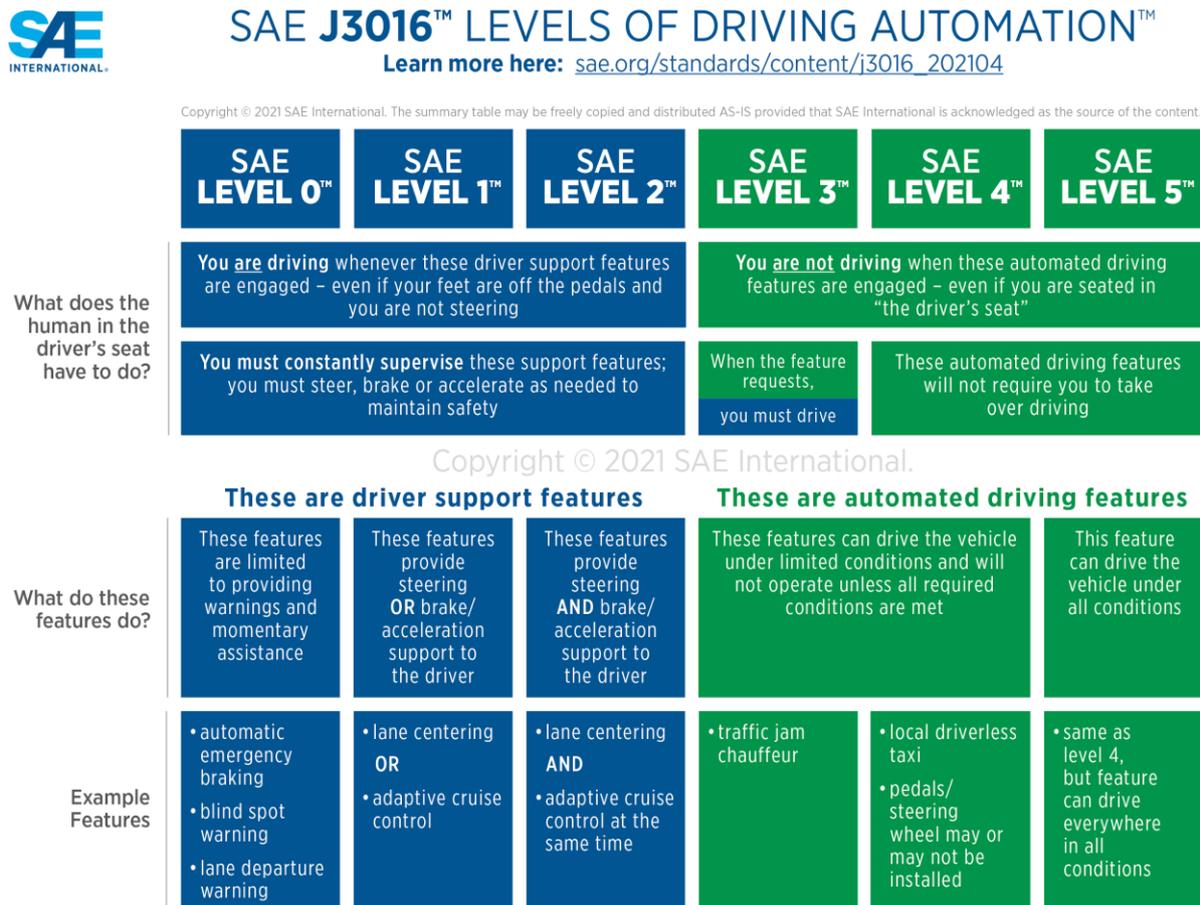
Por lo tanto, primero se recopiló información necesaria para comprender los diferentes elementos que componen un sistema ADAS. Sabiendo el funcionamiento de estos elementos se definió la historia que tomó cada uno de ellos, llegando a la solución más reciente para la detección de problemas. Con estos métodos más recientes se buscaron estudios y tests realizados en el mundo real para obtener una base sobre la cual se definieron los límites



aceptables para cada componente. Con esta información finalmente se definieron los elementos necesarios para la inspección y los procedimientos de dichas inspecciones.

4. FUNCIONAMIENTO DEL SISTEMA AUTÓNOMO

Un sistema autónomo es aquel que toma control parcial o completo del movimiento longitudinal y lateral de un vehículo móvil utilizando sistemas avanzados de asistencia al conductor (ADAS), pudiendo distinguir 6 niveles de automatización siguiendo la clasificación prevista por el SAE (Sociedad de Ingenieros de la Automoción) en la Gráfica 8.



Gráfica 8: “SAE Levels of Driving Automation” [Online]. Disponible en: <https://www.sae.org/blog/sae-j3016-update> [Accedido en: 1-Jun-2022].

Como se puede observar, desde el nivel 0 al 2 inclusive, el conductor debe estar siempre atento, tener las manos en el volante y los pies en el pedal para intervenir en situaciones que requieren mantener la seguridad. Esto significa que estos tres niveles no se consideran automatizaciones si no ayudas al conductor, con un apoyo cada vez más alto, siendo el nivel 2 caracterizado por la asistencia en la dirección y frenado del vehículo. Por el otro lado, desde el nivel 3 hacia arriba se considera el sistema suficientemente autónomo y seguro para que el conductor no tenga que estar siempre atento, aunque en algunos casos, para el nivel 3 en específico, se requiere que el conductor tome control del vehículo entre 3 y 7 segundos [3]. En la actualidad, muchos de los coches autónomos están en un nivel denominado 2.5. Aunque esta denominación no está aprobada por el SAE, se utiliza para definir vehículos que tienen la capacidad del nivel 3, pero los requisitos de seguridad de un nivel dos, causado por ser nueva tecnología sin amplio testeo. Esto crea coches capaces de conducción autónoma, pero la necesidad de que el conductor asume el control del vehículo inmediatamente en caso de emergencia.



Así pues, para conseguir replicar las capacidades de un conductor humano, se deben utilizar elementos y técnicas para reproducir los procesos que se realizan voluntaria o involuntariamente a la hora de toma de decisiones en la carretera. Estos pasos son, observar el entorno, detección de objetos tanto móviles e inmóviles, clasificación de los objetos detectados en categorías, predicción de la evolución del entorno y sus elementos y, por último, toma de decisión del movimiento longitudinal y lateral [4, 5].

Observar el entorno compromete el proceso de recolección de información del entorno que rodea el vehículo en su totalidad (360°), hasta las distancias que sean relevantes. Este paso se realiza con sensores de diferentes tipos los cuales ven el mundo de manera pasiva o activa. La diferencia entre los dos radica que un sensor pasivo como la cámara digital está de manera pasiva esperando que la información, en este caso en forma de fotones, entre al dispositivo para ser captado. Por otro lado, sensores como el Radar o LiDAR envían ondas láser o de radiofrecuencia activamente para ver cómo interactúan con los alrededores.

Tras observar, se realiza la detección de objetos utilizando la información de las salidas de los sensores, diferenciando entre el entorno y objetos móviles o inmóviles que afectan las condiciones de la carretera. Dichos objetos pueden ser otros vehículos, ciclistas, peatones, señales de tráfico, etc. Este paso es de gran importancia, ya que en caso de no detectar un elemento o detectar uno no existente se crea la necesidad para el vehículo de realizar maniobras peligrosas e innecesarias las cuales ponen en peligro los pasajeros y usuarios de la carretera. Después de la detección, se deben clasificar los objetos detectados con anterioridad asignándoles a categorías previamente definidas en base a características de cada objeto. Estas características pueden ser su tamaño, forma, color, velocidad, reflectividad, etc.

Así pues, si sabemos la naturaleza de los objetos que nos rodean, el sistema autónomo puede predecir la evolución de la situación de la carretera. Esto se realiza sabiendo las constantes de las capacidades de cada tipo de actor en la carretera, como por ejemplo la baja velocidad de peatones, y observando el cambio de la escena utilizando la salida de los sensores en un intervalo de tiempo.

Por último, sabiendo los objetos en el entorno, su clasificación y cómo se moverán, el sistema autónomo puede realizar la toma de decisiones para operar de forma segura y eficaz el control del vehículo. Esta toma de decisión corresponderá al trayecto a seguir para llegar al destino decidido con anterioridad. Dicho trayecto puede cambiar y evolucionar dependiendo del mapa del área y la forma en la que cambia por las condiciones de la carretera. Esta información el vehículo lo obtiene por sus localizadores como GPS, algoritmos de mapeo (SfM y SfM) y la información recibida por comunicación con la infraestructura y otros vehículos llamado V2X (Comunicación vehículo-todo). Gracias a ello podemos planear y modificar el camino que sigue nuestro coche adaptándonos a congestiones, accidentes y condiciones atmosféricas.

Todos estos pasos anteriormente mencionados son la base de la toma de decisiones de un sistema autónomo y pueden ser implementados utilizando diferentes estructuras dependiendo del fabricante y los elementos empleados en su construcción. Hace una década todavía utilizábamos algoritmos de detección inflados, teniendo que introducir en el código todos los diferentes casos que podrían ocurrir en la carretera. Además del elevado coste de trabajo y recursos computacionales necesarios para la ejecución de estos algoritmos, su forma de construcción presentaba problemas de seguridad ya que cualquier caso extraordinario e imprevisible podía confundir el sistema. Por otro lado, el precio y calidad de las cámaras y LiDARs era poco aceptable. Esto hacía imposible la comercialización a precios competitivos y la aplicación de las salidas de los sensores de manera efectiva por su baja calidad. Con la revolución de las inteligencias artificiales de los últimos años [6, 7], se han podido emplear en el sector de los automóviles autónomos para todos los pasos del proceso. Gracias a ello, se produjo la proliferación de bases de datos para entrenar dichas inteligencias artificiales mejorando la eficiencia y seguridad del proceso de conducción autónomo. Por otro lado, el avance en tecnología de sensores de imagen, cámaras digitales y LiDAR aumentó la calidad y eficiencia de estas y redujo su coste, siendo posible por primera vez la introducción de un sensor LiDAR en un vehículo autónomo comercial, el Audi A8. Actualmente existe una variedad de soluciones propuestas de modelos de vehículos autónomos por los distintos fabricantes de automóviles, cada uno aportando al avance global de la tecnología.

Tesla es una compañía no solo enfocada en la manufacturación de vehículos, si no baterías eléctricas, cargadores de coches eléctricos y energía solar, así teniendo a su disposición la capacidad de implementar sus propias soluciones electrónicas. Esto implica una reducción de coste y la posibilidad de mejor implementación en los



elementos que necesitan dicha electrónica. Por otro lado, al no tener la suficiente experiencia en el desarrollo automovilístico, su competencia puede sobrepasarlo. Gracias a esta centralización de la producción, se asegura la sinergia entre los diferentes elementos y se reduce el coste en comparación a comprar de un tercero. Hoy en día, su modelo más nuevo es el Modelo 3, apostando por el uso de cámaras y sensores ultrasonidos utilizados como sensores de detección, intentado aumentar sus capacidades de manera física y digital, introduciendo programas de detección con baja luz. Este modelo tiene 8 cámaras [8] en total distribuyéndolos con 3 traseras y 3 delanteras. Las traseras son de medio alcance igual que los dos laterales frontales teniendo una tri cámara frontal en el centro con capacidad estéreo y largo alcance. Por otro lado, los 12 sensores ultrasonidos se reparten por toda la extensión del vehículo, utilizados para aparcar y detección de bordes y carriles. El papel menciona un sistema Radar el cual fue removido a un año de la publicación del estudio. Finalmente, toda la disposición se representa en Fig. 1. Se debe mencionar que todo hardware y software es producido internamente por Tesla.

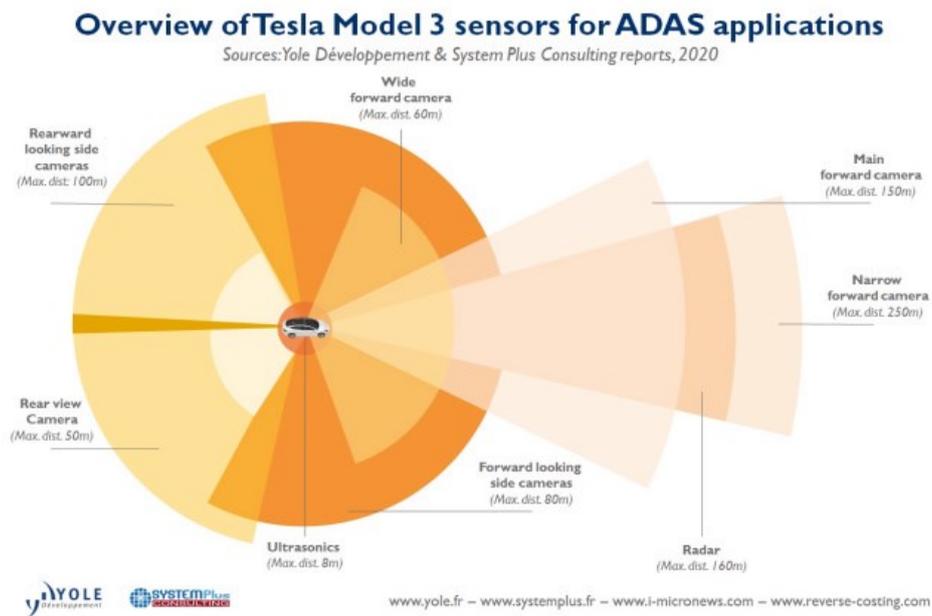


Fig. 1: "Sensores en el Tesla Modelo 3, 2020" [8]

Audi tiene su modelo más reciente en el A8 intentando llegar hasta un nivel 3 de automatización, pero fallando obtener aprobación por los organismos de la UE (Unión Europea). Este vehículo tiene 2 cámaras frontales [9], una de visión nocturna y otro con ángulo de visión 360°, un LiDAR frontal y 5 radares diferenciándose por su radar de largo alcance frontal y de medio alcance para los lados a la derecha e izquierda del vehículo por delante y por detrás. Esto se representa en Fig. 2



Fig. 2: “Sensores en el Audi A8, 2020” [9]

El día 5 de mayo del año 2022 se cerró el periodo de retroalimentación para la regulación 2019/2144 de la UE referente a la introducción de requisitos específicos para vehículos totalmente automatizados (sin conductor necesario) y los sistemas que esta emplea [10]. Pendiente para su adopción en el primer trimestre de 2022, esta regulación introduce los requisitos fundamentales para vehículos autónomos, tanto para su adopción como sus capacidades.

Separado en 4 anexos distintivos, la aportación más importante para el sector se encuentra en los anexos 2 y 3. En el primero se introducen las capacidades mínimas requeridas de un vehículo autónomo sin conductor y en el segundo se discuten los escenarios, pruebas y la posibilidad de utilizar soluciones virtuales para testeo del sistema de conducción autónomo (ADS).

Aunque la adopción de unas bases de capacidades mínimas y la metodología de realización de los test de aprobación es un gran avance en relacionado a sistemas ADAS, la adopción de cadenas de herramientas virtuales para la validación de estos sistemas tiene la posibilidad de revolucionar el sector. En la regulación se delinean 5 características para demostrar la credibilidad de una cadena de herramientas virtuales siendo, su capacidad de realizar diferentes acciones, precisión de reproducir los datos objetivos, exactitud de los datos y algoritmos, facilidad de uso dependiendo del entrenamiento y conocimientos necesarios para operarlo y su aptitud para el propósito de evaluación de ADAS y dominio de diseño operativo (ODD). Por ello, en un futuro cuando tengamos el programa el cual cumple los requisitos expuestos tendremos la capacidad de agilizar y reducir el riesgo de las pruebas sobre el ADAS. Esto es un progreso significativo ya que actualmente este proceso de prueba puede tomar gran cantidad de tiempo para demostrar la capacidad de un sistema autónomo de operar en todos los escenarios y condiciones posibles. Introduciendo el proceso a un programa virtual podremos realizar este test sobre escenarios pre creados o implementar una inteligencia artificial para crear multitud de escenarios para nuestra prueba, manteniendo unas restricciones para ello.

En conclusión, podemos observar la evolución e implementación de sistemas de conducción autónomos, su implementación modular en la actualidad y los avances de no solo las tecnologías dentro de estos coches sino también los sistemas que testean dichos vehículos de manera virtual. Con la futura aprobación de la regulación 2019/2144 de la UE se abre una nueva etapa de la automoción en toda España y la posibilidad de crecimiento de esta industria dentro de nuestros bordes.



5. COMPONENTES INDIVIDUALES

5.1 Sensores

Teniendo la misión de observar el entorno y recopilar datos de él, son un componente obligatorio para cualquier sistema ADAS para que se tenga información sobre el que se toman las decisiones. Aunque se listan los tres sensores utilizados en la automoción, la más utilizada con diferencia es la cámara por su bajo precio, gran cantidad de información que recolecta y amplias tecnologías (color, visión nocturna y térmica). Por el contrario, si se utilizan sensores Radar o LiDAR en un coche autónomo, estos observarán solo el lado frontal para concentrarse hacia donde se mueve el vehículo. Por ello, aunque se pueden utilizar varias configuraciones y disposiciones de los sensores, utilizar cámaras para observar todos los lados y solucionar los problemas inherentes del diseño tiene prioridad.

5.1.1 Cámara

La cámara es un sensor que detecta imágenes del mundo en 2D utilizando un efecto parecido al de un ojo humano. Estas imágenes son sus salidas y pueden variar dependiendo del rango y campo de visión del sensor. Se pueden diferenciar 5 elementos que componen una cámara.

Las lentes fotográficas cumplen la función de recoger (converger) la luz del exterior en el punto focal para pasar por el filtro de Bayer [48]. Este tiene la misión de, dependiendo de la intensidad de luz en cada cuadrado, sacar uno de los colores fundamentales por área. Luego estos colores fundamentales son transferidos a un sensor de imagen el cual lo convierte a formato eléctrico para que por último, estas salidas crudas sean transferidas al procesador de señal de la imagen (ISP) para ser procesadas creando la imagen digital final limpia y sin ruidos [11].

Dependiendo del objetivo de uso podemos diferenciar entre cámaras de largo alcance, cámaras estéreo utilizan dos cámaras para observar la profundidad en 3D y cámaras con visión nocturna. Luego dependiendo del tipo de luz que observan se tienen 3 diferentes tipos, siendo cámara infrarrojo cercano (NIR) el cual recibe luz infrarroja, cámara VIS detecta según la reflexión de luz, cámara térmica detecta la energía infrarroja que emiten los objetos y cámara de tiempo de vuelo (ToF) mide distancias.

Con relación al historia y evolución de las técnicas de detección con cámaras, la detección de objetos móviles utilizando imágenes estáticas es un problema que existió desde que Toyama los definió en 1999[12] siendo expandido y solucionado con el paso de los años:

- Empaquetado
- Camuflaje
- Fondo dinámico
- Apertura en primer plano
- Cambios en iluminación
- Velocidad de fotogramas baja:
- Desenfoque de movimiento
- Paralaje
- Fondo en movimiento
- Objeto de fondo movido
- Video de noche
- Imagen con ruido
- Sombras
- Objeto de primer plano parada
- Objeto de primer plano movimiento



Considerando que, por la naturaleza del uso, un vehículo autónomo tiene cámaras móviles, utiliza varias de sus imágenes para crear una de mayor tamaño llamado panorama o mosaico. La evolución de este método se observa en la tabla 2 expandido en el artículo [13]:

Autor	Año	Contribución
Mittal et al.	2000	Construcción de mosaico con objetos móviles
Bhat et al.	2000	Construcción de mosaico y modelado de fondo
Bartoli et al.	2002	Construcción de mosaico
Hayman et al.	2003	Modelado de fondo
Kang et al.	2003	Reducción de ruido de segmentación
Sugaya et al.	2004	Construcción de mosaico
Azzari et al.	2005	Construcción de mosaico
Ali and Shah	2006	Combinación de métodos
Bevilacqua et al.	2006	Alineación de tono
Asif et al.	2008	Detección de objetos móviles
Vivet et al.	2009	Construcción de mosaico
Amri et al.	2010	Operador de mediana temporal
Xue et al.	2010	Construcción de mosaico
Zhang et a	2010	Zoom grande
Xue et al.	2013	Zoom grande
Hamid et al	2014	Acelerar emparejamiento de cuadros
Liu et al.	2015	Modelo de fondo jerárquico
Avola et al	2017	Seguimiento de puntos clave espaciotemporales
Moore et al	2019	Fondo panorámico de bajo rango
Chelly et al.	2020	Subespacio local parcialmente superpuesto

Tabla 2: "Soluciones panorámicas para cámara"

Otros métodos utilizan soluciones estéreo para construir el panorama requiriendo modelos diferentes (Tabla 3):

Autor	Año	Contribución
Lim et al.	2003	Técnica de control basado en imagen
Horraud et al	2006	Calibración con geometría epipolar
Chen et al	2008	Dos métodos de mapeo espacial
Krahnstoeber et al.	2008	Combinación de varias cámaras



Kumar et al.	2009	Método de rectificación en tiempo real
Cui et al.	2014	Registración de imagen en tres pasos

Tabla 3: “Soluciones estéreo para cámara”

Compensación de movimiento se utiliza para aplicar la sustracción de fondo sobre una cama móvil compensando la moción para poder realizar la sustracción en un caso de cámara estática.

Actualmente el sensor más utilizado en coches autónomos es la cámara por su gran versatilidad, capacidad de detección y clasificación. Por otro lado, a causa de su reducido FOV en comparación con otros sensores, se suele utilizar al menos una de ellas por cada lado del vehículo. Por ello, gracias a esta restricción, es por la frente del vehículo donde se ve la mayor necesidad de precisión y rango, considerando que es la dirección de avance y encuentro más frecuente con otros vehículos.

Modelos desarrollados por diferentes compañías como Tesla, Audi y Mercedes utilizan cámaras por todos los lados del vehículo intentando conseguir solapamiento de los FOV entre ellos para reducir los puntos ciegos. Esto se puede observar perfectamente en la Fig. 1 anteriormente explicada del Tesla Model 3. Como se mencionó, al ser la frente del vehículo el lado más significativo en términos de la detección, normalmente aquí se tienen cámaras de largo alcance, estéreo y visión nocturna.

Así pues, todas estas disposiciones tienen el objetivo final de entregar una imagen digital a un algoritmo de detección de objetos. Estas imágenes al tener formas, colores y bordes distintivos para los diferentes objetos de la captura dan una mayor cantidad de información para detectar y clasificar los elementos en comparación a otros sensores. Es decir, los algoritmos esperan de diferentes objetos como vehículos, personas o bicicletas, colores, formas y bordes determinados a su clase, facilitando la detección y clasificación.

Por desgracia, como la salida generada es una imagen en 2D, es difícil estimar profundidad y por ello la distancia entre el sensor y el objeto detectado. Los problemas de profundidad se pueden contrarrestar con la utilización de cámaras en modo estéreo (cámaras duales), cámaras ToF y emparejamiento con otros tipos de sensores no afectados por este fenómeno. Es importante mencionar que dicho emparejamiento requiere una calibración precisa, para que el contraste de información entre los dos sensores esté en el mismo rango y unidad.

Por otro lado, bajo situaciones adversas de baja o muy alta luminosidad se vuelve cada vez más ineficiente la detección por la naturaleza misma del funcionamiento de una cámara y su necesidad de tener un número elevado de fotones. Soluciones para este problema utilizadas en el pasado incluyen aumentar la apertura de las lentes y el tiempo de exposición con el objetivo de incrementar la luz que entra a la cámara. También es posible elevar la sensibilidad del ISO aumentando el brillo de la imagen. Estas tres soluciones, aunque incrementan el brillo, también introducen desenfoque fuera de foco, desenfoque de movimiento y ruido, dificultando la detección. Un nuevo método propuesto por [14] introduce un módulo pre entrenado para mejorar la imagen en condiciones de baja luz. Los resultados de mejora son consistentes pero despreciables por su reducido aumento de detección gracias a ello.

Al contrario, problemas también pueden originar en la salida misma de nuestra cámara, con fallos en las diferentes partes antes mencionadas. Por ejemplo, un fallo de bandeo es causado por un error en el sensor de la cámara y produce líneas horizontales y verticales en la imagen final. Otro sería la presencia de condensación en el lente exterior desviando la luz y alterando la imagen. En la Tabla 4 del apéndice, de fuente [11], se pueden observar todos los fallos que puede sufrir una cámara digital, especificando el componente afectado y las entradas y salidas de dicho componente.

Utilizando la fuente [11] como base, se llegó a la conclusión que la utilización del programa de detección de objetos llamado Disp R-CNN o similar, para obtener un promedio de detección denominado en la precisión media (AP) a 89,94 % o mayor, es recomendable en el caso de búsqueda de posibles fallos. Los resultados del mencionado estudio para casos sin fallos se representan en la tabla ().



Algorithm	Metric	AP on clean images (%)	Max AP (%)	Failure configuration for Max AP
FastBox	2D AP	86.63	87.25	DIRTY
SqueezeDet	2D AP	86.49	87.05	BAND1
SqueezeDet+	2D AP	88.82	89.15	DIRTY
ResNet50	2D AP	87.90	88.33	DIRTY
DSGN	2D AP	89.67	91.81	BLUR (2,2)
	3D AP	70.80	71.18	BRLE
Disp R-CNN	2D AP	89.94	90.08	SHARP 0
	3D AP	57.89	63.14	DEAPIX-vcl

Tabla. 5: “Promedio de detecciones en la cámara” [11]

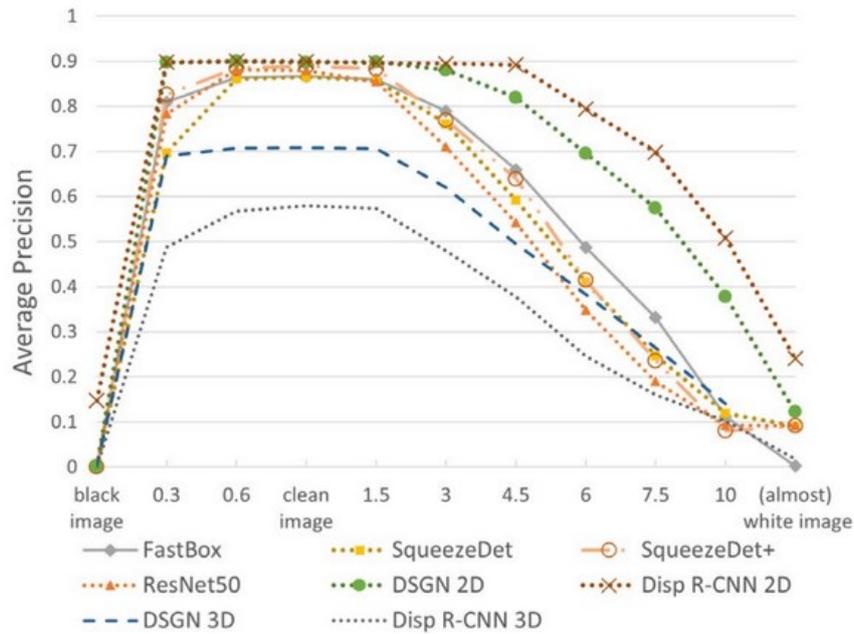
Para mostrar comparación a casos de fallo, la Tabla 6 representa los fallos por rotura de lente, suciedad y lluvia, la Tabla 7 describe AP aberración cromática, la Gráfica 8 muestra la precisión media para brillo cada vez mayor y el valor de AP fallo de ruido cada vez mayor en la Tabla 9.

	AP	BRLE %			DIRTY %			RAIN %		
		min	max	avg	min	Max	avg	min	max	avg
FastBox	2D	68	87	83	78	87	86	38	87	71
SqueezeDet	2D	69	86	83	74	87	84	33	86	67
SqueezeDet+	2D	72	89	87	78	89	88	41	88	74
ResNet50	2D	60	87	82	78	88	86	21	87	67
DSGN	2D	87	90	89	88	90	90	81	90	87
	3D	64	71	69	66	71	69	50	70	62
Disp R-CNN	2D	81	90	89	89	90	90	71	90	84
	3D	48	58	56	53	63	57	27	58	48

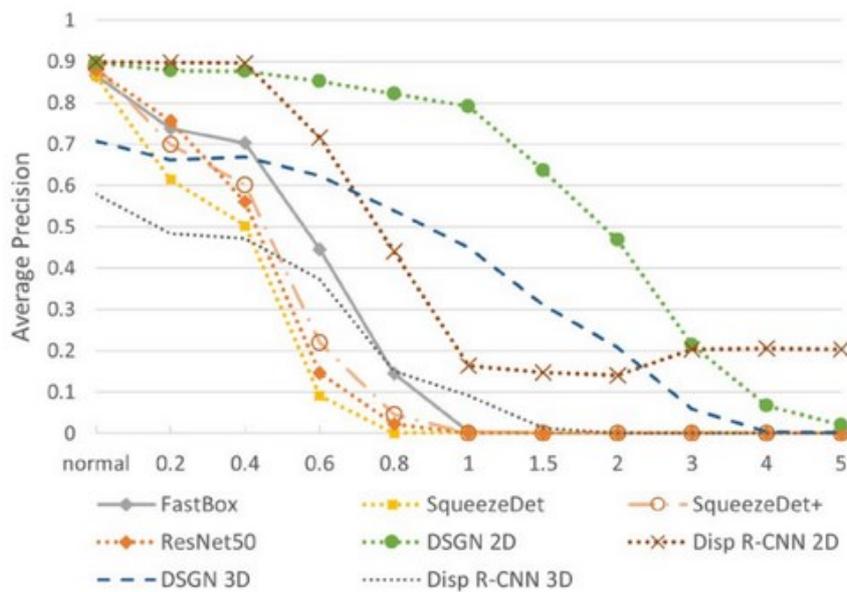
Tabla. 6: “Promedio de detecciones en la cámara con rotura, suciedad y lluvia” [11]

	AP (%)	CHROM	CHROM	CHROM	CHROM
		AB1-nb	AB1-b	AB2-nb	AB2-b
FastBox	2D	23.03	9.58	6.98	0.81
SqueezeDet	2D	42.16	20.72	23.86	5.01
SqueezeDet+	2D	52.79	27.66	29.89	13.53
ResNet50	2D	56.44	18.35	34.08	6.94
DSGN	2D	58.43	58.97	23.56	29.44
	3D	1.17	1.00	0.33	0.68
Disp R-CNN	2D	79.76	60.51	67.89	37.63
	3D	2.45	3.03	9.09	9.09

Tabla. 7: “Promedio de detecciones en la cámara con aberración cromática” [11]



Gráfica 8: "Promedio de detecciones en la cámara con diferentes brillos" [11]



Gráfica 9: "Promedio de detecciones en la cámara con diferentes cantidades de ruido" [11]

5.1.2 LiDAR:

Un sensor LiDAR opera escaneando su campo de visión (FOV) con una o varios haces de láser, los cuales son rotados con un sistema de dirección. La generación del haz de láser ocurre en un diodo de láser con modulación de amplitud el cual emite a una longitud de onda infrarroja. Dicho haz es luego reflejado por el entorno y es recibido por el escáner compuesto por fotodetectores para luego filtrar la señal y medir la diferencia entre la señal emitida y recibida. Esta diferencia es utilizada para hallar la distancia al objeto del cual se refleja el haz y representar el punto de dicho objeto creando una nube de puntos en un entorno virtual 3D. Por otro lado, la variación de la intensidad producida por el material por el que se refleja el láser y el medio por el que viaja es compensado con el procesamiento de la señal. Todo este proceso está dividido en tres apartados. El telémetro láser, el cual mide la distancia al objeto, transmisión y recepción del láser encargado de generar y recibir las



señales láser y por último el sistema de escaneo, encargado de orientar el haz de láser en el azimut y ángulos verticales. Todo esto es visualizado en la Fig. 3.

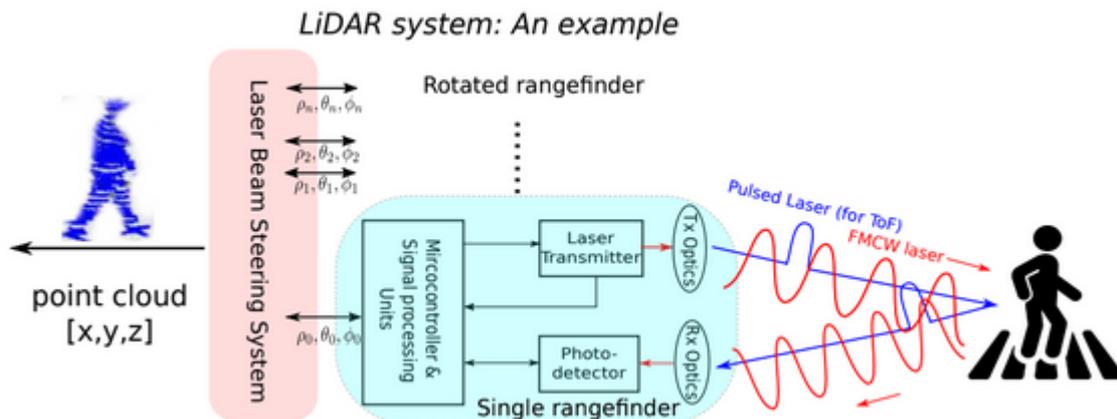


Fig. 3: “Esquema de un LiDAR” [15]

Los elementos de telémetro láser y transmisión y recepción cumplen su función con elementos digitales y electrónicos internos, dificultando la revisión visual ya que su correcto funcionamiento no es observable desde el exterior. También su arquitectura y tecnologías utilizadas no influyen en la revisión de fallos, ya que un cambio de tecnología seguirá dibujando una nube de puntos, solo variando valores como precisión y rango. Sin embargo, el sistema de escaneo es un elemento mecánico encargado de dirigir el haz de láser y dependiendo de las tecnologías utilizadas, la inspección visual cambia. El enfoque en la inspección por ello es si este elemento mecánico es móvil o rígido teniendo en la actualidad estas cuatro soluciones de [15] con visualización en la Fig.4:

1. **Rotación mecánica:** Consiste en un espejo interno que refleja el haz de láser saliente variando su ángulo vertical moviendo dicho espejo, mientras que su azimut es ajustado por la rotación de la base, así aumentando su FOV horizontal a 360°. Esta solución ofrece una alto ratio de señal a ruido (SNR) por un amplio FOV a cambio de un cuerpo abultado y propensa a error por vibración del vehículo. Gracias a esto, es importante la observación de su correcto funcionamiento mecánico.
2. **MEMS Micro-Escaneador:** Es una solución de integración de un espejo rotatorio dentro de un chip. El movimiento de rotación del espejo es realizado con las fuerzas electromagnéticas al conducir electricidad por la bobina integrada al borde del espejo, y la fuerza elástica de la barra de torsión el cual sujeta el espejo al circuito. Esta barra proporciona el eje del espejo y puede ser singular para movimiento 1D o doble para movimiento 2D. Si el MEMS opera en su frecuencia de oscilación característica se dice que trabaja en modo resonante obteniendo un alto ángulo de deflexión y alta frecuencia de operación. En modo no resonante el espejo sigue una trayectoria programada. Es una solución de bajo coste y difícil de revisar a simple vista por su posicionamiento en el interior del LiDAR.
3. **Flash:** Un método estático es el Flash en el cual se difumina una señal sobre un área creando una nube de puntos sin utilizar ninguna parte móvil. Esta solución no es afectada por la compensación de movimiento por el sensor ya que todos los puntos son medidos al mismo tiempo, pero esto reduce su rango (<100 m) y FOV. Es una tecnología de bajo coste e internó al LiDAR siendo imposible su revisión visual. La única forma de revisión es la observación de la cantidad de puntos en la nube de puntos por la totalidad del FOV o su comparación con una referencia conocida.
4. **Óptica de matriz en fase (OPA):** Este método es capaz de dirigir el haz de luz a través del uso de moduladores de fase. Se puede cambiar la velocidad de la luz con moduladores de fase óptica cuando el láser pasa por las lentes. Por ello diferentes velocidades en diferentes trayectorias, permite controlar la forma de onda óptica y por ello la dirección. La solución promete los mejores resultados de las cuatro opciones, pero todavía no existen soluciones comerciales.

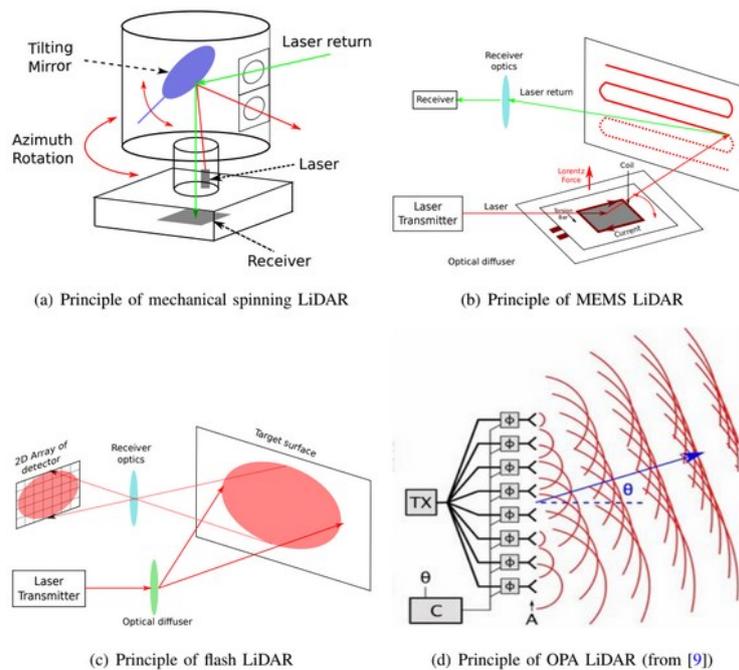


Fig. 4: “Tipos de elementos mecánicos en LiDAR” [15]

Los diferentes principios de emisión para las diferentes formas de medición han sido utilizado a través de los años distinguiéndose tres de ellos estudiados en [16] de la Tabla 8:

	Pulso	AMCW	FMCW
Medida del parámetro	Intensidad de pulso emitido y recibido	Fase de amplitud modulada	Ritmo relativo de frecuencia modulada y efecto Doppler
Medición	Directa	Indirecta	Indirecta
Detección	Incoherente	Incoherente	Coherente
Uso	Exterior/Interior	Solo interior	Exterior/Interior
Ventajas	Sencillez de configuración y largo rango de resolución de ambigüedad	Establecido comercialmente	Medida simultánea de velocidad y rango
Desventajas	Bajo SNR de pulso devuelto	Corta distancia de ambigüedad	Longitud de coherencia/Estabilidad en condiciones de operación (Ej.:térmico)
Resolución de profundidad	1 cm	1 cm	0.1 cm

Tabla 8: “Principios de emisión para LiDAR” [16]

Las estrategias de creación de imágenes son varias y siempre en aumento, pero las más conocidas por sus aportaciones a la evolución continua del medio, estudiados en [16] de la Tabla 9:



	Escaneo Mecánico	Escaneo MEMS	Flash	OPAs
Principio de funcionamiento	Especios y prismas giratorios	Microespecios MEMS	Iluminación por inundación pulsada	Antenas de matriz de fase
Ventajas	FOV de 360° en horizontal	Compacto y ligero	Rápida velocidad de fotogramas	Estado sólido completo
Desventajas	Elementos móviles y abultado	Gestión de energía láser y linealidad	Rango limitado y posible de cegar	Largo alcance sólo para laboratorio

Tabla 9: "Creación de imágenes en LiDAR" [16]

Por otro lado, las fuentes del LiDAR, refiriéndose al tipo de elementos que emite la señal láser, pueden ser de tres tipos, estudiados en [16] para la Tabla 10:

	Fibra láser	Láser de microchip	Láser de diodo
Medio de amplificación	Fibra óptica dopada	Cristal semiconductor	Unión PN de semiconductor
PRR	>10 kW	>1 kW	0.1 kW
Potencia pico	<1 MHz	<1 MHz	≈100 KHz
Ancho de pulso	<5 ns	<5 ns	100 ns
Ventajas	Alto pico de pulso de potencia, PRR, calidad del haz y entrega de haz	Alto pico de pulso de potencia, PRR y calidad del haz	Bajo precio y compacto
Desventajas	Alto precio	Alto precio, entrega de haz	Entrega de potencia y PRR máximo y calidad del haz

Tabla 10: "Fuentes de LiDAR" [16]

Existen 5 tecnologías de fotodetectores para LiDAR, estudiados en [16] de la Tabla 11:

	PIN	APs	SPADs	MPPCs	PMTs
Estado sólido	Sí	Sí	Sí	Sí	No
Ganancia	1	Lineal (≈200)	Geiger (10 ⁴)	Geiger (10 ⁶)	Avalancha (10 ⁶)
Ventajas	Rápido	Ganancia ajustable por sesgo	Detección de fotón singular	Conteo de fotón singular	Ganancia y detección UV
Desventajas	Limitado a SNR bajo	Ganancia limitada	Tiempo de recuperación	Posible de saturar y dependencia del voltaje de polarización	Abultado, bajo QE, necesita altos voltajes y es afectado por campos magnéticos

Tabla 11: "Fotodetectores para LiDAR [16]



En cuanto al objetivo final de un sistema LiDAR, este es la de generar una nube de puntos y transmitirlo al algoritmo de detección de objetos, teniendo la forma como en la Fig. 5.

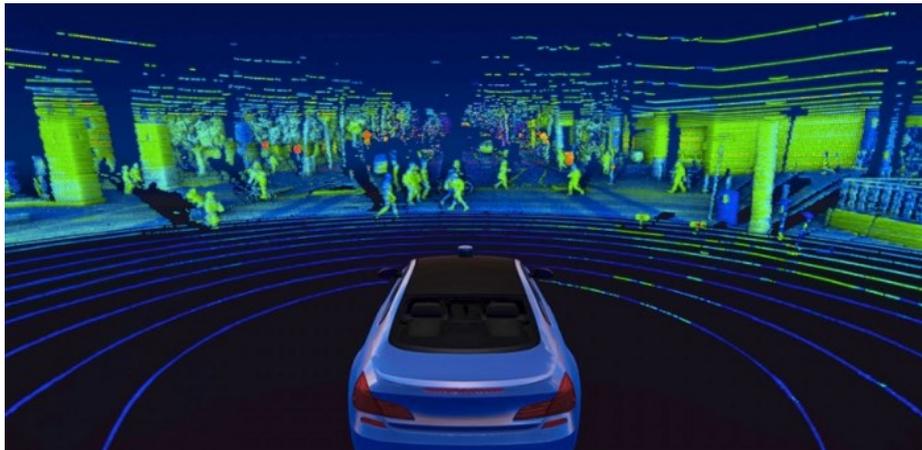


Fig. 5: “What’s LiDAR and What’s 3D Point Cloud?” [Online]. Disponible en: <https://becominghuman.ai/whats-lidar-and-what-s-3d-point-cloud-1f4ccd998e7b> [Accedido en: 14-Jun-2022].

Gracias a la naturaleza del sensor, el LiDAR no es afectado por falta de luz externa y solo es levemente perjudicado por condiciones climáticas de lluvia y neblina. Asimismo, la salida de nube de puntos no presenta suficientes tipos de información para la clasificación exacta de los objetos detectados en comparación a la cámara digital, aunque su capacidad de obtener el contexto de la escena lo diferencia del radar y eleva sus capacidades. Por desgracia, en la actualidad el precio elevado de un sensor LiDAR (>10.000 euros) limita su utilización en el sector civil, pero cuando se consiga superar esta barrera y reducir costes su implementación será esencial junto a la cámara gracias a los beneficios que trae.

Como se comentó, en la actualidad la implementación de un sensor LiDAR en el sector civil es prohibitivamente costoso, pero esto no ha parado a compañías automovilísticas de renombre mundial adoptar dicha tecnología para sus soluciones de automatización. Gracias a su tamaño y precio, en modelos de la compañía Audi se utiliza un LiDAR Aptiv R3TR [9] único debajo del capó delantero del coche para observar en un reducido ángulo frontal (fig.5)



Fig. 6: “Descomposición del Radar en el Audi A8” [9]



Es decir, por esta implementación el modelo A3 se considera el primer automóvil de autonomía nivel 3 (aunque no aprobado por la UE). Otros casos del uso del LiDAR en vehículos civiles todavía no se ha observado fuera de prototipos y por ello no podemos comentar en la comparación de los diferentes posicionamientos de dicho sensor.

En cuanto a problemas de errores y fallas en un sensor LiDAR se manifiestan en forma de fallos en los diferentes elementos anteriormente presentados. En la siguiente tabla se enumeran los que pueden ocurrir al LiDAR utilizando [17]:

Componente	Condición de fallo	Efecto
Encoder de posición	Falla en leer datos de posición	Funcionamiento defectuoso del motor del espejo
Eléctrico	Cortocircuito	Fallo eléctrico
Eléctrico	Sobretensión	Fallo eléctrico
Receptor óptico	Desalineación	Error en el receptor óptico
Filtro óptico	Dañado	Error en el receptor óptico
Motor del espejo	Funcionamiento defectuoso	Fallo del LiDAR
		Radiación del láser

Tabla 12: “Fallos en el LiDAR” [17]

Referente a las soluciones de detección de objetos, el mejor modelo es una combinación del método de clasificación por redes y nube de puntos denominado PV-RCNN [18], mejorado en una nueva iteración llamado PV-RCNN++ [19]. Teniendo un alto rendimiento y menor consumo de memoria su único problema es el tiempo necesario para producir resultados en comparación con otros métodos. Este inconveniente no es relevante en nuestro caso ya que nosotros no estamos operando en el rango de respuesta en tiempo real.

Este modelo funciona en dos pasos:

1. El primer paso es seleccionar un pequeño número de puntos clave, utilizando muestreo de punto más lejano, así asegurando una distribución uniforme y representativa de la nube de puntos. El muestreo de punto más lejano consiste en unos pasos los cuales se repiten iterativamente con el objetivo de representar un grupo (voxel) con menos puntos de lo necesario. Como primer paso se selecciona un punto clave para muestrear, para luego saltar al punto más lejano del grupo y repetir el muestreo. Por último, se debe seleccionar el punto más cercano al anterior y muestrear otra vez.
El método se denomina Voxel CNN con 3D. Las características (rasgos) de cada punto muestreado se agregan agrupándolos con su red vecina. De esta forma se obtiene una red con características que representan un mayor número de puntos.
2. El segundo paso es, teniendo cada voxel con su localización en la red, se juntan las características de cada punto del grupo a un punto central, llamado punto de la cuadrícula, el cual representa la totalidad del grupo. Luego estos puntos centrales son agregados a un área de interés para el refinamiento de la propuesta, determinar qué tipo de objeto es y predicción de confianza. Esto crea las áreas de interés en forma de nuevos grupos, pero estos abarcando una mayor área.

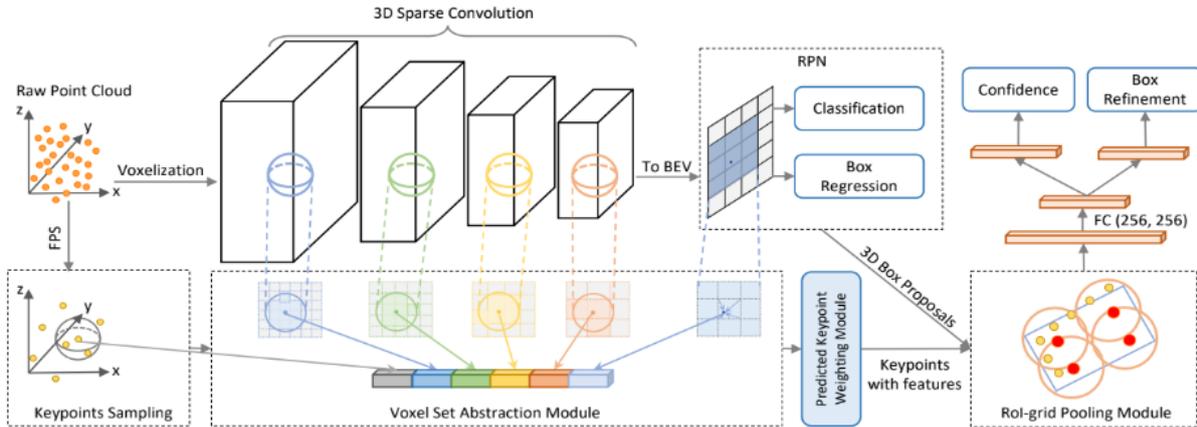


Fig. 7: “Explicación gráfica del proceso de la solución PV-RCNN” [18]

Gracias a esta solución se obtiene de una red los puntos centrales, los cuales retienen localización precisa y el contexto de la escena, describiendo qué tipo de objeto se observa. También al agrupar estos puntos en áreas de interés se consigue refinar el bounding box (caja imaginaria que encierra cada objeto detectado) y el contexto de la escena.

Con la versión mejorada de este módulo llamado PV-RCNN++ se introducen dos nuevos módulos mejorando la precisión y eficiencia. Uno es la introducción de estrategia sectorizada centrada en la propuesta para mejorar el muestreo de puntos clave y el segundo es el módulo de agregación VectorPool mejorar la efectividad de la agregación de características locales de nubes de puntos a gran escala.

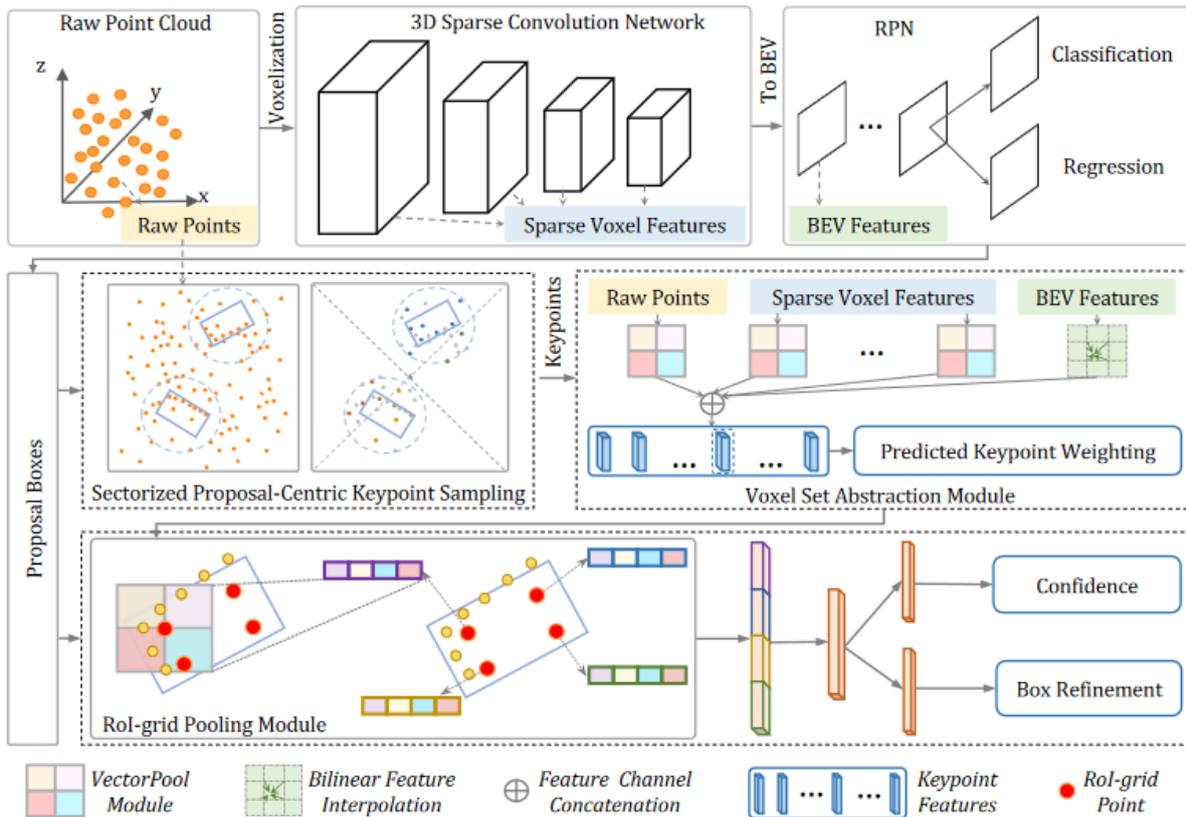


Fig. 8: “Explicación gráfica del proceso de la solución PV-RCNN++” [19]

Para nuestro caso, este método presenta la mejor alternativa considerando las soluciones obtenidas en KITTI 3D benchmark para los valores del promedio medio de precisión (mAP). En este test para la versión PV-RCNN,



visible en la Tabla 13, se obtuvo 81,43% en modo 3D y 90,65% en vista de pájaro para detección media de coches. Por otro lado, se consiguió 63,71% en modo en 3D y 68,89% en vista de pájaro para detección media de ciclistas.

Method	Reference	Modality	Car - 3D Detection			Car - BEV Detection			Cyclist - 3D Detection			Cyclist - BEV Detection		
			Easy	Mod.	Hard	Easy	Mod.	Hard	Easy	Mod.	Hard	Easy	Mod.	Hard
MV3D [1]	CVPR 2017	RGB + LiDAR	74.97	63.63	54.00	86.62	78.93	69.80	-	-	-	-	-	-
ContFuse [17]	ECCV 2018	RGB + LiDAR	83.68	68.78	61.67	94.07	85.35	75.88	-	-	-	-	-	-
AVOD-FPN [11]	IROS 2018	RGB + LiDAR	83.07	71.76	65.73	90.99	84.82	79.62	63.76	50.55	44.93	69.39	57.12	51.09
F-PointNet [22]	CVPR 2018	RGB + LiDAR	82.19	69.79	60.59	91.17	84.67	74.77	72.27	56.12	49.01	77.26	61.37	53.78
UberATG-MMF [16]	CVPR 2019	RGB + LiDAR	88.40	77.43	70.22	93.67	88.21	81.99	-	-	-	-	-	-
SECOND [34]	Sensors 2018	LiDAR only	83.34	72.55	65.82	89.39	83.77	78.59	71.33	52.08	45.83	76.50	56.05	49.45
PointPillars [12]	CVPR 2019	LiDAR only	82.58	74.31	68.99	90.07	86.56	82.81	77.10	58.65	51.92	79.90	62.73	55.58
PointRCNN [25]	CVPR 2019	LiDAR only	86.96	75.64	70.70	92.13	87.39	82.72	74.96	58.82	52.53	82.56	67.24	60.28
3D IoU Loss [39]	3DV 2019	LiDAR only	86.16	76.50	71.39	91.36	86.22	81.20	-	-	-	-	-	-
Fast Point R-CNN [2]	ICCV 2019	LiDAR only	85.29	77.40	70.24	90.87	87.84	80.52	-	-	-	-	-	-
STD [37]	ICCV 2019	LiDAR only	87.95	79.71	75.09	94.74	89.19	86.42	78.69	61.59	55.30	81.36	67.23	59.35
Patches [13]	Arxiv 2019	LiDAR only	88.67	77.20	71.82	92.72	88.39	83.19	-	-	-	-	-	-
Part-A2-Net [26]	TPAMI 2020	LiDAR only	87.81	78.49	73.51	91.70	87.79	84.61	-	-	-	-	-	-
PV-RCNN (Ours)	-	LiDAR only	90.25	81.43	76.82	94.98	90.65	86.14	78.60	63.71	57.65	82.49	68.89	62.41
Improvement	-	-	+1.58	+1.72	+1.73	+0.24	+1.46	-0.28	-0.06	+2.12	+2.35	-0.07	+1.65	+2.13

Tabla 13: “Promedio de precisión de detecciones en el LiDAR para PV-RCNN en la base de datos KITTI” [18]

Repitiendo la misma prueba, pero para el base de datos de Waymo Open Dataset, con los resultados en la Tabla 14, diferenciando entre nivel 1 y 2 (level 1 y 2), siendo el primero para objetos de verdad fundamental con al menos 5 puntos internos y el segundo lo mismo, pero con 1 punto interno, siendo este más restrictivo. Se obtuvieron 81,43% en modo 3D y 90,65% en vista de pájaro para detección media de coches. Por otro lado, se consiguió 63,71% en modo en 3D y 68,89% en vista de pájaro para detección media de ciclistas.

Method	Reference	Vehicle (LEVEL 1)		Vehicle (LEVEL 2)		Ped. (LEVEL 1)		Ped. (LEVEL 2)		Cyc. (LEVEL 1)		Cyc. (LEVEL 2)	
		mAP	mAPH	mAP	mAPH	mAP	mAPH	mAP	mAPH	mAP	mAPH	mAP	mAPH
*StarNet [20]	NeurIPS 2019	53.70	-	-	-	66.80	-	-	-	-	-	-	-
*PointPillar [12]	CVPR 2019	56.62	-	-	-	59.25	-	-	-	-	-	-	-
*MVF [40]	CoRL 2019	62.93	-	-	-	65.33	-	-	-	-	-	-	-
†SECOND [34]	Sensors 2018	72.27	71.69	63.85	63.33	68.70	58.18	60.72	51.31	60.62	59.28	58.34	57.05
PV-RCNN (Ours)	-	77.51	76.89	68.98	68.41	75.01	65.65	66.04	57.61	67.81	66.35	65.39	63.98

Tabla 14: “Promedio de precisión de detecciones en el LiDAR para PV-RCNN en la base de datos Waymo Open Dataset” [18]

Por último, repitiendo la misma prueba de KITTI para la versión mejorada de PV-RCNN++ se ven modestas mejoras en la detección de algunos elementos en la Tabla 15. En otras palabras, se demuestra que la versión mejorada PV-RCNN++ es la ideal para nuestro caso.

Method	Modality	3D Detection (Car)			BEV Detection (Car)			3D Detection (Ped.)			BEV Detection (Ped.)			3D Detection (Cyc.)			BEV Detection (Cyc.)		
		Easy	Mod.	Hard	Easy	Mod.	Hard	Easy	Mod.	Hard	Easy	Mod.	Hard	Easy	Mod.	Hard	Easy	Mod.	Hard
MV3D [9]	R+L	74.97	63.63	54.00	86.62	78.93	69.80	-	-	-	-	-	-	-	-	-	-	-	-
ContFuse [13]	R+L	83.68	68.78	61.67	94.07	85.35	75.88	-	-	-	-	-	-	-	-	-	-	-	-
AVOD-FPN [11]	R+L	83.07	71.76	65.73	90.99	84.82	79.62	50.46	42.27	39.04	58.49	50.32	46.98	63.76	50.55	44.93	69.39	57.12	51.09
F-PointNet [20]	R+L	82.19	69.79	60.59	91.17	84.67	74.77	50.53	42.15	38.08	57.13	49.57	45.48	72.27	56.12	49.01	77.26	61.37	53.78
UberATG-MMF [17]	R+L	88.40	77.43	70.22	93.67	88.21	81.99	-	-	-	-	-	-	-	-	-	-	-	-
3D-CVF at SPA [72]	R+L	89.20	80.05	73.11	93.52	89.56	82.45	-	-	-	-	-	-	-	-	-	-	-	-
CLOCs [91]	R+L	88.94	80.67	77.15	93.05	89.80	86.57	-	-	-	-	-	-	-	-	-	-	-	-
SECOND [16]	L	83.34	72.55	65.82	89.39	83.77	78.59	-	-	-	-	-	-	71.33	52.08	45.83	76.50	56.05	49.45
PointPillars [15]	L	82.58	74.31	68.99	90.07	86.56	82.81	51.45	41.92	38.89	57.60	48.64	45.78	77.10	58.65	51.92	79.90	62.73	55.58
PointRCNN [21]	L	86.96	75.64	70.70	92.13	87.39	82.72	47.98	39.37	36.01	54.77	46.13	42.84	74.96	58.82	52.53	82.56	67.24	60.28
3D IoU Loss [92]	L	86.16	76.50	71.39	91.36	86.22	81.20	-	-	-	-	-	-	-	-	-	-	-	-
STD [23]	L	87.95	79.71	75.09	94.74	89.19	86.42	53.29	42.47	38.35	60.02	48.72	44.55	78.69	61.59	55.30	81.36	67.23	59.35
Part-A2-Net [24]	L	87.81	78.49	73.51	91.70	87.79	84.61	53.10	43.35	40.06	59.04	49.81	45.92	79.17	63.52	56.93	83.43	68.73	61.85
3DSSD [81]	L	88.36	79.57	74.55	92.66	89.02	85.86	54.64	44.27	40.23	60.54	49.94	45.73	82.48	64.10	56.90	85.04	67.62	61.14
Point-GNN [93]	L	88.33	79.47	72.29	93.11	89.17	83.90	51.92	43.77	40.14	55.36	47.07	44.61	78.60	63.48	57.08	81.17	67.28	59.67
PV-RCNN (Ours)	L	90.25	81.43	76.82	94.98	90.65	86.14	52.17	43.29	40.29	59.86	50.57	46.74	78.60	63.71	57.65	82.49	68.89	62.41
PV-RCNN++ (Ours)	L	90.14	81.88	77.15	92.66	88.74	85.97	54.29	47.19	43.49	59.73	52.43	48.73	82.22	67.33	60.04	84.60	71.86	63.84

Tabla 15: “Promedio de precisión de detecciones en el LiDAR para PV-RCNN++ en la base de datos KITTI” [19]

5.1.3 Radar:

Un sensor radar escanea su FOV con ondas electromagnéticas obteniendo una nube de puntos similar a un sensor LiDAR. Esto se consigue midiendo el tiempo que tarda la onda desde ser enviado hasta que rebote en la superficie del objeto y vuelva (ToF), de esta forma calculando distancia, ángulo y velocidad del elemento detectado.

La estructura de un sensor radar tiene tres elementos, el transmisor, el receptor y el procesador de señales [20]:



1. El transmisor para un radar tiene el objetivo de generar la señal electromagnética y su rango depende del diseño del transmisor, su antena, y la potencia que consume dicha antena. El diseño del transmisor está compuesto del generador de onda, superconvertidor de bloque (up converter) y el amplificador de potencia. La potencia que emite la antena debe primero ser regulada, el cual supone restricciones al rango máximo y solo puede ser aumentado al elevar la potencia.
2. El receptor recibe las señales enviadas por el transmisor intentando maximizar la ratio de señal a ruido y de esa forma reducir las señales no deseadas que se presentan por el ruido y señales de otras fuentes. Las partes que lo componen son el amplificador de bajo ruido (LNA) y el convertidor digital descendente.
3. El procesador de señales utiliza la señal recibida por el receptor para extraer información necesaria para determinar la posición, seguimiento y clase del objeto a detectar, utilizando los algoritmos implementados en él. La complejidad del algoritmo implementado es clave, considerando la posible existencia de ruidos en la señal. Por otro lado, por limitaciones de espacio, recursos y la necesidad de una respuesta en tiempo real, es posible que la complejidad del algoritmo sufra reduciendo su capacidad.

Dependiendo del rango del radar se utilizan tres rangos de frecuencias. Radares de corto alcance (SRR) están en el rango de 24 GHz, radares de largo alcance (LRR) están alrededor de 76 GHz y por último radares de medio alcance (MRR) se sitúan entre 76-81 GHz. Por otro lado, dependiendo del rango utilizado se emplean diferentes ángulos de emisión siendo el SRR a 160° con alcance de 20 a 50 metros, el LRR a 30° y 250 metros de rango y el MRR el cual está entre 100-150 metros y ángulo entre SRR y LRR [20].

Las técnicas de imágenes de radar se remontan a 1951 cuando se introdujo el Procesamiento del desplazamiento Doppler. La teoría principal siempre fue filtro adaptado, esté siendo un proceso lineal teniendo como ventaja su simplicidad y estabilidad, pero su rendimiento es limitado por el ancho de banda de la señal. Esta idea fue mejorada y luego reemplazado por nuevas introducciones al área de técnicas de imágenes de radar expuestas en la Tabla 16 de [21] y [22]:

Autor	Año	Contribución
Carl Wiley	1951	Procesamiento del desplazamiento Doppler
Emmett Leith	1953	Radar de apertura sintética (SAR)
Cutrona et al.	1957	Procesamiento óptico
MacDonald Dettwiler	1978	Procesamiento digital y Algoritmo de rango Doppler
Jin, M. Y., y Wu, C.	1984	Algoritmo de rango Doppler modificado
S.L. Marple	1987	Algoritmo ωK
W.F.Gabriel	1989	Imágenes de radar de super-resolución
Alberto Moreira	1994	Algoritmo de escala de Chirp
John W. McCorkle	1996	Algoritmo rápido de retroproyección
M. Cetin; W.C. Karl	2000	Imágenes radar de regulación



Richard Baraniuk; Philippe Steeghs	2007	Imágenes radar de detección comprimida
------------------------------------	------	--

Tabla 16: “Evolución de técnicas de imágenes Radar” [21]

En la actualidad existen dos tecnologías de radares para detección en vehículos autónomos en utilización, el radar de onda milimétrica (MMW) y el radar fotónico (Fig.9):

1. Radar de onda milimétrica (MMW) [22] y [23]: Utilizando los elementos básicos antes mencionados, emiten radiaciones de radiofrecuencias a una amplia apertura del diámetro (divergencia) del transmisor dificultando la detección ya que otros objetos exteriores pueden entrar en el barrido.
2. Radar Fotónico [24]: En esta solución se envían señales ópticas con radiofrecuencias por un transmisor óptico para luego ser recibido al reflejarse. Por ser una señal óptica, está tendrá poca divergencia comparada a un radar MMW y también consume menos energía en las bandas de frecuencia de 75-77 GHz, donde se obtiene más resolución y menos atenuación por condiciones climáticas.

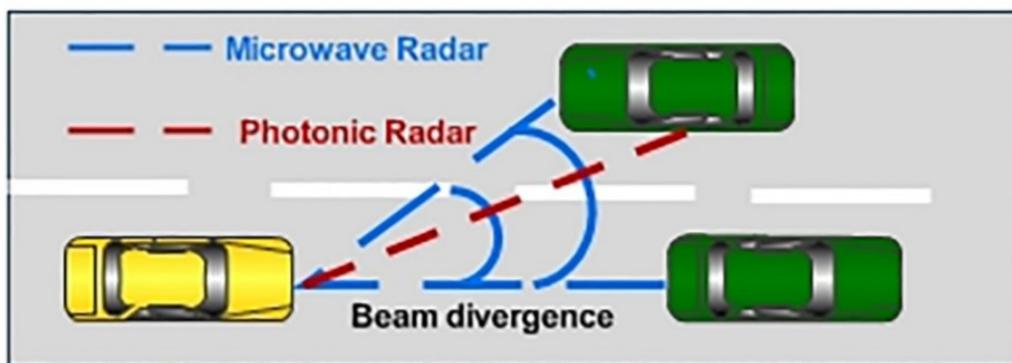


Fig. 9: “Campo de visión de diferentes Radares” [24]

Por otro lado, similar al LiDAR la salida es una nube de puntos representados en un espacio 3D para un rango de 360°, menos en soluciones implementadas en vehículos autónomos [9] (45° en horizontal en el datasheet de Continental ARS4-B [25]). Esta salida se entrega al algoritmo de detección, siendo capaz de alocar puntos de objetos detectados a hasta 250 m de distancia sin ser afectado por condiciones climáticas adversas. Sí también contamos su bajo coste, se puede ver la utilidad y alta preferencia de implementación en soluciones de automatización. Por desgracia, el radar tiene su salida a una resolución angular baja, dando la necesidad de aumentar el ancho de banda y por ello el consumo de poder computacional. También se debe comentar que la nube de puntos generada carece de información semántica dificultando la clasificación de los objetos. Por último, la imposibilidad con tecnología actual de completamente eliminar el ruido genera detecciones erróneas las cuales afectan el comportamiento del vehículo de una manera drástica [24].

Fallos y errores que pueden afectar el funcionamiento del radar se pueden manifestar en varios subsistemas, alterando o imposibilitando medidas. Estos elementos que pueden fallar se representan en la Tabla 17 localizado en el apéndice para la fuente [26]:

Al igual que en el método propuesto para el LiDAR y cámara, la puesta en servicio de un radar y su utilización en las comprobaciones para ITV, sería instalar un radar por encima del vehículo a comprobar (en la plataforma de sujeción de sensores) y comparar las soluciones obtenidas de los dos radares respectivamente. Se recomienda mejor un radar de alta capacidad con FOV 360° y recortar las soluciones para la posición y FOV del radar del vehículo a testear ajustándose lo máximo posible y así obteniendo resultados iguales.



A la hora de analizar la capacidad de los radares en la inspección técnica, los parámetros a tener en cuenta son la posición, velocidad, FOV, tipo del objeto, tamaño del objeto y visibilidad del objeto (VIS) definido en forma de porcentaje. Para obtener estos valores se deben realizar varios pases de los radares ya que la realización de solo una reduce la posibilidad de detección y normalmente los métodos utilizados en coches autónomos emplean varios antes de proporcionar información al ADAS [27].

En cuanto a los algoritmos principales para la detección por radar, existen estos métodos actualmente [28]:

1. Clustering and recurrent neural network classifier
2. Semantic segmentation network and clustering
3. Grid Mapping + YOLOv3
4. Point-cloud-based object detection network
5. Combined semantic segmentation and recurrent neural network classification approach (Point Net++ + DBSCAN + LSTM)

Utilizando estos métodos debemos ver si la salida obtenida del radar del vehículo a inspeccionar se acerca lo suficiente a nuestros puntos de referencia determinado según la intersección sobre unión basado en pixels (IOU):

$$IOU = \frac{|punto\ predicho \cap punto\ de\ referencia|}{|punto\ predicho \cup punto\ de\ referencia|}$$

Siendo un IOU de 0.5, el valor más común y moderadamente restrictivo, será este el empleado para luego sacar los valores del promedio medio de precisión (mAP) utilizando el promedio de detección media para todas las clases, y la tasa promedio de fallas (LAMR), está siendo el promedio de objetos no detectados. Estos 2 últimos serán los que decidirán si el Radar detecta de manera correcta comparado con el Radar de referencia.

Los resultados de la Tabla 18 se presentan a continuación:

Table 2 Result scores for all main methods on the test set

Method	IOU=0.3					IOU=0.5												
	AP _{ped}	AP _{grp}	AP _{cyc}	AP _{car}	AP _{trk}	mAP	mLAMR	F _{1,pt}	F _{1,obj}	AP _{ped}	AP _{grp}	AP _{cyc}	AP _{car}	AP _{trk}	mAP	mLAMR	F _{1,pt}	F _{1,obj}
DBSCAN/LSTM	22.96	42.95	62.51	65.21	59.07	50.54	53.10	53.06	58.92	22.94	41.07	62.51	63.13	56.36	49.20	54.90	53.08	57.60
DBSCAN/RandomForest	20.67	37.28	53.98	59.63	56.53	45.62	59.68	49.48	52.43	20.60	35.23	53.76	55.91	50.97	43.29	61.58	49.50	51.10
PointNet++/DBSCAN	29.42	53.06	56.37	53.15	26.19	43.64	61.10	54.55	51.67	27.47	47.56	54.85	49.16	21.10	40.03	64.17	54.37	49.24
YOLOv3	28.28	57.51	64.87	75.54	62.18	57.67	48.92	53.04	61.87	26.96	54.88	63.68	67.99	56.31	53.96	52.61	52.86	59.46
PointPillars	15.13	32.28	46.40	61.19	47.48	40.50	65.46	47.62	45.92	14.67	30.42	45.08	54.38	39.87	36.89	68.55	47.70	43.75
PointPillars++	24.69	47.32	55.39	68.72	53.08	49.84	57.01	53.91	55.61	23.93	44.66	53.58	61.33	45.62	45.82	60.36	53.93	53.36
PointNet++/LSTM	27.28	56.28	64.94	68.44	60.21	55.43	50.10	54.13	60.99	27.17	51.70	64.88	63.74	57.00	52.90	52.06	54.12	59.64

For all scores except mLAMR higher means better. The methods are listed in the order of appearance in the text. The best scores are indicated in bold font

Tabla 18: “Promedio de precisión de detecciones en el Radar” [28]

Las dos soluciones más notables son el del YOLOv3 y la combinación de Point Net++ + DBSCAN + LSTM. Mientras que el método YOLOv3 devuelve los mejores resultados por un margen de 2%, la segunda opción al ser un sistema modular da la oportunidad de mejora si se llega a actualizar cualquiera de sus componentes individuales. Si se llega a perfeccionar la segmentación semántica, agrupamiento, algoritmos de clasificación, la adición de un rastreador o mejora de tecnología del radar se prevé que se mejore el rendimiento de este método. En conclusión, se implementará el método Point Net++ + DBSCAN + LSTM para inspecciones y revisión de errores en el radar.

5.2 Localización y mapeo:

Con el objetivo de planear la ruta en el cual viajará el vehículo, mapear el entorno y recibir actualizaciones del estado de la carretera e inmediaciones en tiempo real, los diferentes elementos que cumplen esta misión son de gran importancia.

Localización y predicción de camino son normalmente conseguidos por la fusión de información conseguida por GPS, cámaras LiDARs, sensores de movimiento inercial (IMU), localización y mapeo simultáneo (SLAM) y CP



(posicionamiento cooperativo) a través de V2X (vehículo-todo). Utilizar sólo 1 de ellos para localización, predicción de caminos y mapeo presenta problemas de fiabilidad, y por ello en un sistema completo se debe fusionar varios de ellos para obtener resultados satisfactorios.

5.2.1 GPS:

La estructura de un GPS consiste en una antena y un conversor de señal de radio a señal digital. El elemento de control, frecuentemente encontrado en sistemas de navegación de vehículos y teléfonos móviles, no se considera ya que este forma parte de los sistemas de entretenimiento y control de ruta. Los dos elementos anteriormente mencionados son de simple construcción y funcionamiento y por ello de fácil revisión [29].

Está compuesto por 3 elementos necesarios para recibir la señal, siendo el primero 1 de los 24 satélites que orbitan la tierra y envían información al segmento de control el cual lo recibe y corrige enviándolo de vuelta para que los datos enviados directamente por el satélite al usuario sean precisos. La información enviada consiste en frecuencias, distancias entre el usuario y satélite, localización del satélite y compensación de reloj.

Es importante recalcar que el GPS sólo da posicionamiento preciso cuando se tiene 4 o más satélites en órbita y en el caso de que la línea de visión entre el satélite y el vehículo no esté bloqueada físicamente o por superficies reflejantes.

Como la única función de este dispositivo es recibir las señales y traducirla a información legible para computar sobre ella, el sistema de navegación simplemente ve si se reciben datos de los satélites y si dichos datos corresponden a la posición actual. Gracias a esto, la salida del GPS está conectado directamente a la unidad computacional para que este pueda calcular una ruta óptima a seguir.

Por eso mismo los fallos presentados en el dispositivo del usuario se representa en la Tabla 19 de [30]:

Componente	Condición de fallo	Efecto
Hardware	Error de lectura de datos de navegación	<ul style="list-style-type: none">● Fallo al obtener los datos de navegación del mensaje recibido.● Fallo de hardware● Ruido eléctrico
Puerto de salida	Salida mal formateada	<ul style="list-style-type: none">● Dato erróneo por puerto de salida certificado
Elemento computacional	Error algorítmico	<ul style="list-style-type: none">● La suposición puede conducir a niveles de protección demasiado optimista

Tabla 19: "Fallos en el GPS" [30]

5.2.2 CP para comunicación vehículo-todo (V2X):

Con el objetivo de comunicación e intercambio de información entre el vehículo autónomo y el mundo exterior se instalan estos dispositivos capaces de enviar y recibir información de otros vehículos en la carretera y estaciones fijas (infraestructura). La modalidad V2X denomina la variable de comunicación entre el vehículo y todos los demás usuarios posible. Para toda la rama de la comunicación mencionada anteriormente, se tienen diferentes tipos de soluciones cumpliendo el mismo objetivo, pero utilizando tecnologías diferentes.

Su construcción consiste en un procesador de V2X, radio definida por software (SDR), sistema global de navegación por satélite (GNSS) y la antena.

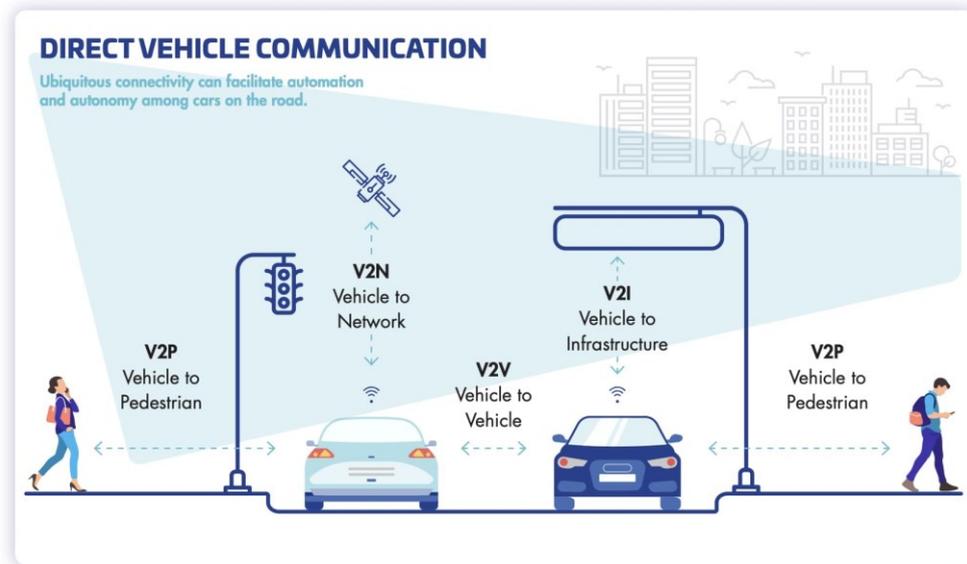


Fig. 10: “Comunicación V2X” [Online]. Disponible en: <https://www.thalesgroup.com/en/markets/digital-identity-and-security/iot/industries/automotive/use-cases/v2x>. [Accedido en: 3-Jun-2022].

En cuanto a la evolución de comunicación vehículo-todo, este venía motivado por compañías de automóviles con el propósito de consolidar tecnología R & D en comunicaciones para vehículos autónomos. Los avances más significativos se representan en la Tabla 20 de [31]:

Autor	Año	Título
Luc Tytgat	1999	Sistema e-Call de llamada de emergencia
D. Somnath; S. Ghoshal	2001	Capacidad de diagnóstico remoto
Axel Nix; Andrew Gellatly	2003	Elemento de acceso a la red para informar del estado del vehículo y navegación paso a paso
Continental	2009	Comunicación V2V / V2I (vehículo-infraestructura) para intercambio de información.
Instituto de Ingenieros Eléctricos y Electrónicos (IEEE)	2010	IEEE 802.11p acceso inalámbrico estándar para UE.
Hitachi	2011	Ayuda a peatones para cruzar paso de peatones el cual informa a vehículos en el área (ceder paso).
Guerrero de Mier et al.	2012	Sistemas de comunicación para grabar y manejar elementos de la carretera basados en consultas y respuestas de un nodo central
Continental	2014	Telemática de datos y comunicaciones 4G/LTE con punto de acceso Wifi



Traffic Technology Service	2015	Comunicación servidor en la nube para conocer el estado de las luces de tráfico y predecir acciones futuras con ello.
Honda	2016	Comunicación de datos (posición, velocidad, etc.) de vehículos a peatones en intersecciones
Samsung	2017	Sistema de comunicación para aportar datos de los vehículos a otros actores (infraestructura, peatones y ciclistas) en áreas críticas.
Third Generation Partnership Project (3GPP)	2019	Comunicación celular C-V2X estandarizado para 5G

Tabla 20: “Evolución de comunicación vehículo-todo” [31]

Además, soluciones de CP pueden utilizar Intercambio de información con otros vehículos móviles o estaciones fijas (normalmente en posiciones altas). En [32], se demuestra que soluciones de este tipo utilizando UWB para V2X pueden llegar a precisiones de hasta pocos centímetros. Este proceso normalmente se realiza en conjunto con GPS para que este funcione en espacios abiertos mientras que el CP soluciona los problemas del GPS en carreteras obstruidas por túneles, rascacielos o espacios subterráneos.

Actualmente existen dos soluciones para el problema de conectividad, V2X: c-v2x [33] utilizando tecnología móvil y el estándar IEEE 802.11p [34] para Comunicaciones de corto alcance dedicado (DSRC) aprobado por la Unión Europea. Como no sabemos qué rumbo tomará el futuro de las comunicaciones y que marcas que tecnología adoptarán, analizaremos las dos soluciones más probables:

- **IEEE 802.11p (DSRC -> ITS-G5 en EU):** Funciona a base de antenas y ondas de radio con anchos de banda entre 10 y 20 MHz y transferencia de datos entre 3 y 27 Mbps.
Aunque la tecnología utiliza un artículo de 2013, su extensa explicación y continua relevancia para sistemas DSRC hace que pueda ser utilizada en la [34] para realizar un test similar a la hora de comprobar el funcionamiento del V2X.
En nuestro caso la configuración consistirá en un ordenador para ejecutar código y un interfaz de red el cual enviará su paquete por una antena.
Para realizar el test primero debemos seguir el protocolo 802.11p, para el cual se utiliza un programa de Java para enviar paquetes de tipo Unidifusión geográfica, Difusión de ámbito topológico, Difusión de un solo salto y Transmisión de alcance geográfico o Unidifusión mensajes. Estos envíos se consiguen con paquetes UDP. También se debe considerar que, para nuestro test, tenemos un límite de 1400 bytes por paquete y por ello probaremos enviando cada paquete de 100 a 1400 bytes de tamaño.
Por último, se debe testear la latencia. Esto se consigue enviando una petición de eco de protocolo de mensaje de control de internet. Más tarde estos datos deben ser recibidos y analizados en un ordenador conectado al vehículo (por cable ethernet) para ver si se reciben los paquetes.
Se debe añadir que las distancias de test serán mucho menores a la de operación en carretera, considerando que el rango máximo es de 1 km, aunque esto no debería afectar las soluciones a la hora de ver si los dispositivos de comunicación funcionan correctamente.
- **C-V2X (PC5, 4G, 5G):** Este método, de [33] y [35], utilizará un RSU (lo mismo que el elemento anterior) para transmitir y recibir mensajes normalizados de Mensaje de Atención Cooperativa (CAM), Mensaje de Notificación Ambiental Descentralizado (DENM) y Mensaje de Información de Infraestructura a Vehículo (IVIM). Estos mensajes se enviarán eligiendo un canal en la banda ITS de 5,9 MHz. Para manejar y almacenar los datos transmitidos y recibidos se debe utilizar un programa (Ej.:



CAMINO) el cual también debe poder postprocesar dichos resultados para dar las métricas necesarias a continuación. En el postprocesado se cuantifican el ratio de paquetes entregados (PDR), ratio de paquetes perdidos y latencia extremo a extremo de una dirección (E2E). Ya que se está transmitiendo y recibiendo se utilizan tanto los datos recibidos por el vehículo como el RSU. Los resultados obtenidos en [33] para V2I, el cual será nuestro método de inspección, se presentan en las Tablas 21 para PDR, 22 para latencia y Fig. 11 para pérdidas de paquete.

AVERAGE PDR OF ITS-G5 AND C-V2X PC5 FOR DISTANCE BINS OF 50 METERS FOR RSU1 AND RSU5.

Distance (m)	Average PDR for RSU1 (%)		Average PDR for RSU5 (%)	
	ITS-G5	C-V2X PC5	ITS-G5	C-V2X PC5
0	98	100	85	97
50	97	100	88	97
100	97	99	86	98
150	97	98	81	99
200	96	100	78	99
250	93	100	78	99
300	85	100	73	97
350	70	96	59	94
400	57	92	44	90
450	54	86	34	80
500	48	75	22	60
550	43	68	13	32
600	39	56	12	16
650	27	36	12	10
700	12	16	13	10
750	4	3	14	13
800	1	1	10	9
850	0	0	4	4

Tabla 21: “Resultado de ratio de paquetes entregados” [33]

AVERAGE LATENCY OF ITS-G5 AND C-V2X PC5 FOR PERCENTILES IN STEPS.

Percentile	Latency (ms)	
	ITS-G5	C-V2X PC5
5	1.43	14.57
10	1.71	15.43
20	1.71	17.14
30	2.00	18.42
40	2.00	19.86
50	2.43	20.86
60	2.43	22.43
70	2.71	24.00
80	2.86	25.71
90	3.00	29.00
95	3.29	33.20
96	3.86	35.13
97	5.48	37.84
98	25.47	41.23
99	121.23	45.03
100	515.57	50.57



Tabla 22: “Resultado de latencia extremo a extremo de una dirección” [33]

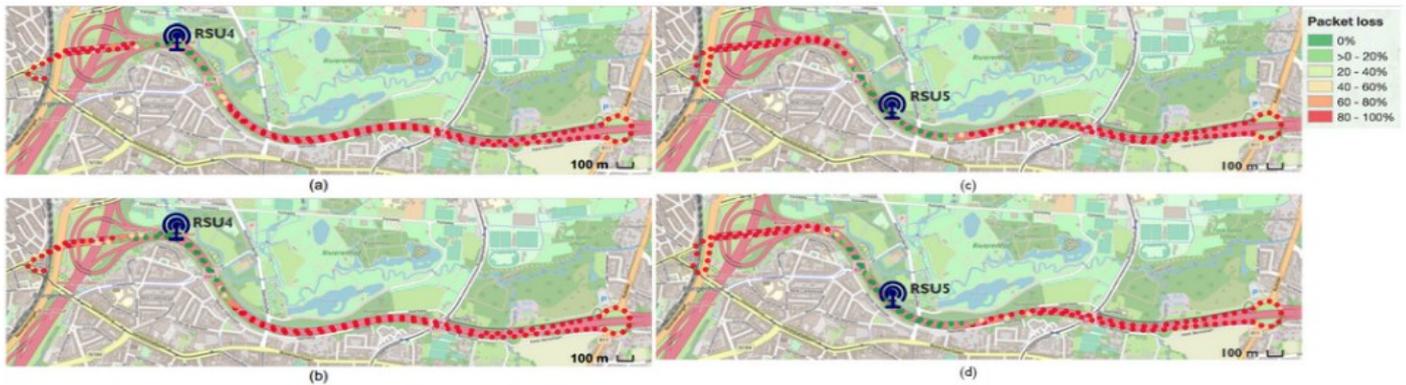


Fig. 11: “Resultado de ratio de paquetes perdidos” [33]

El mencionado método es posible utilizarlo también para el DSRC, ya que los requisitos necesarios para su funcionamiento son los mismos, aunque la forma de llegar a ellos es diferente.

5.2.3 Unidad de medición inercial (IMU):

El IMU tiene el objetivo principal de medir la velocidad, ángulo y fuerza gravitacional del vehículo utilizando acelerómetros y giroscopios. Gracias a ello se pueden medir las distancias recorridas a través del cálculo acumulativo de las velocidades y ángulos diferentes medidos durante un trayecto. Su funcionamiento de cálculo utilizando medidas consecutivas induce un error acumulativo siendo difícil reducirlo una vez que entró en el sistema [36].

Existen dos tipos de tests para IMUs, el test estático y el test dinámico [37]. El primero consiste en dejar el IMU en posición y observar si cambian sus datos sin moverse (no debería cambiar) en un periodo de entre 1 y 8 horas. Por ello este test se descarta.

Por otro lado, el test dinámico es tener en movimiento el IMU, algo posible de hacer si el vehículo o las ruedas de dicho vehículo se mueven. Considerando la posibilidad de un IMU por rueda cada uno se conectaría a la unidad computacional y sabiendo el sistema de coordenadas del IMU, este se transforma a un sistema de coordenadas preferente para nosotros. Después el vehículo debe moverse, en nuestro caso sus ruedas. Esto se consigue teniendo el coche sobre la cinta omnidireccional para mover artificialmente las ruedas en las direcciones esperadas. Sabiendo exactamente la distancia que debe recorrer el vehículo, esto se compara a los resultados de los IMUs. Desviaciones pequeñas al principio pueden traducirse a errores de gran magnitud y por ello debemos observar las desviaciones no solo finales si no iniciales. Siguiendo estándares impuestos en los Estados Unidos, la precisión no debe ser menor a 95% error de desplazamiento lateral y longitudinal mayor a 0,3 m y error de orientación de 0,50°. Estos estándares son los más restrictivos, siendo utilizados para casos de conducción en carreteras urbanas y por ello serán los utilizados en la inspección.

5.2.4 Localización y mapeo simultáneos (SLAM):

SLAM consiste en la estimación del estado del vehículo y la construcción de un mapa del entorno que los sensores perciben a través de un algoritmo. El primero compromete la descripción de la posición, orientación, velocidad, errores sistemáticos de los sensores y los parámetros de calibración. En cambio, el mapeo considera las posiciones de interés del entorno alrededor del vehículo [38].

La utilización de un mapa se utiliza para la planificación de movimiento y para limitar errores cometidos al estimar el estado del vehículo creando dichos mapas en tiempo real para retirar la necesidad de una infraestructura de localización.

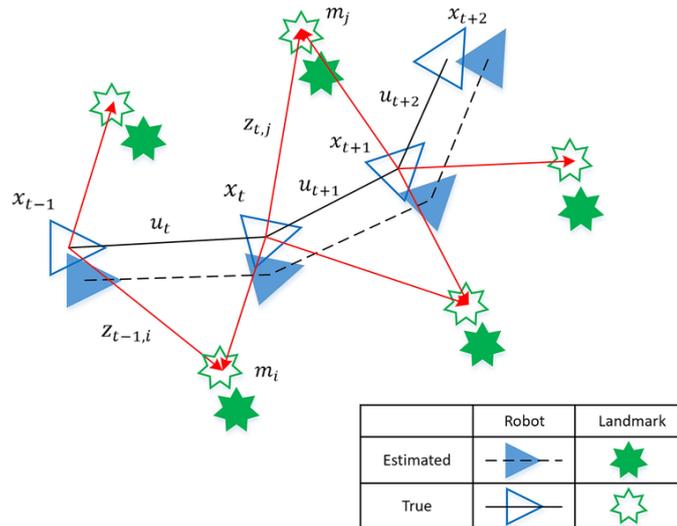


Fig. 12: “Diagrama del SLAM” [49]

Dependiendo del sensor si es de tipo visual, tipo LiDAR o ambos, los sistemas de SLAM cambian [39]. Los avances desde la década del 2000 han visto una gran variedad de soluciones y metodologías para su diseño para los dos tipos. Considerando el elevado número de estos, en la siguiente tabla, separado en los tres tipos de utilización de los sensores, se explicarán los métodos básicos empleados, pero no el funcionamiento de tecnologías individuales. Estos solo serán numerados en orden de su creación.

Primero se consideran las soluciones con sensores visuales los cuales se reparten en 5 posibles acercamientos dependiendo de si la imagen obtenida lo utilizamos en método directo, con construcciones semiDensos y densos, o en un método basado en características con construcción disperso. Otra solución que considerar es la Odometría inercial visual (VIO), soluciona problemas procedentes del movimiento rápido, pequeño campo de visión, cálculos grandes, oclusión, pérdida de rasgos, escenas dinámicas y cambios de nivel lumínico. El último método es utilizar aprendizaje profundo para determinar información semántica aumentando el rendimiento. Estos se representan en la Tabla 23 localizada en el apéndice.

Luego se consideran las soluciones con sensores LiDAR (Tabla 24) los cuales se reparten en los de 2D, 3D y aprendizaje profundo, el cual emplea rasgos y detección, reconocimiento y segmentación y localización:

Método	Construcción	Tecnología
LiDAR 2D		<ul style="list-style-type: none"> ● Gmapping: (2007) por Giorgio Grisetti et al. ● HectorSLAM: (2011) por Stefan Kohlbrecher et al. ● KartoSLAM: (2010) por Kurt Konolige et al. ● CoreSLAM: (2010) por B. Steux et al. ● LagoSLAM: (2012) por Luca Carlone et al. ● Cartographer: (2016) por Wolfgang Hess et al.
LiDAR 3D		<ul style="list-style-type: none"> ● Loam: (2014) por Ji Zhang et al. ● Cartographer: (2016) por Wolfgang Hess et al. ● Leg-Loam: (2018) por Tixiao Shan et al. ● IMLS-SLAM: (2018) por Jean-Emmanuel et al.
Aprendizaje profundo	Rasgos y detección	<ul style="list-style-type: none"> ● MV3D: (2017) por Xiaozhi Chen et al. ● PointNetVLAD: (2018) por Mikaela Angelina et al. ● VoxelNet: (2018) por Yin Zhou et al. ● LMNet: (2018) por Kazuki Minemura et al. ● PIXOR: (2018) por Bin Yanget al. ● Yolo3D: (2018) por Waleed Ali et al.



		<ul style="list-style-type: none"> ● PoinyCNN: (2018) por Yangyan Li et al. ● PU-GAN: (2019) por Ruihui Li et al.
	Reconocimiento y segmentación	<ul style="list-style-type: none"> ● PointNet: (2016) por Charles R. Qi et al. ● PointNet++: (2017) por Charles R. Qi et al. ● VoteNet: (2017) por Charles R. Qi et al. ● SegMatch: (2017) por Renaud Dubé et al. ● Kd-Network: (2017) por Roman Klokov et al. ● SegMap: (2018) por Renaud Dube et al. ● SqueezeSeg: (2018) por Bichen Wu et al. ● PointSift: (2018) por Mingyang Jiang et al. ● PointWise: (2018) por Binh-Son Hua et al. ● 3P-RNN: (2018) por Xiaoqing Ye et al. ● DeepTemporalSeg: (2019) por Ayush Dewan et al. ● LU-Net: (2019) por Pierre Biasutti et al.
	Localización	<ul style="list-style-type: none"> ● SuMa++: (2018) por Chen Xieyuanli et al. ● L3-Net: (2019) por Lu Weixin et al.

Tabla 24: “Evolución de soluciones con LiDAR” [39]

Por último, sistemas de fusión de los dos sensores para SLAM no ha sido muy implementado en la actualidad ya que aunque existe una solución software y hardware de HESAI con LiDAR de 40 haces y 5 cámaras de color, no existe un chip y hardware integrado con el objetivo de vender como producto al sector automovilístico. Por ello no podemos considerar esta solución en la actualidad

Sin importar los sensores empleados en el algoritmo de SLAM este debe de tener la capacidad de crear puntos de referencia los cuales son distinguibles y necesarios para corregir errores y saber localizaciones al revisitar los. En nuestra inspección referente al SLAM utilizaremos esta funcionalidad para verificar el parecido del mapa creado con el de referencia. Se utilizará sistema SLAM con LiDAR 3D con tecnología IMLS-SLAM [42]. El modelo del LiDAR se delimitará en el apartado de “Requisitos para instalación”.

Esto será conseguido comparando el mapa y puntos de referencia de las inmediaciones del taller ITV, sabiendo que todos los vehículos que llegan a la inspección deberán haber tomado ese camino. Así al descargar el mapa generado seremos capaces de encontrar los parecidos y diferencias entre un mapa creado con anterioridad para referencia, del área antes mencionado y el del coche a inspeccionar.

Como regla general dicho mapa debe tener como mínimo 100 pases y un alejamiento máximo de 0.6%, utilizando como referencia la Tabla 25 de [42].

Parameter n	Drift on KITTI training dataset
$n = 1$ scan	1.41%
$n = 5$ scans	0.58%
$n = 10$ scans	0.56%
$n = 100$ scans	0.55%

Tabla 25: “Alejamiento por n° de pases para el base de datos KITTI” [41]

Si la distribución de la carretera genera caminos alternativos al taller, los cuales posibilitan un acercamiento diferente al de la referencia, primero se buscarán coincidencias de carreteras generales necesarias para el acceso, segundo se buscarán coincidencias de carreteras generales, caminos o autopistas frecuentadas en las inmediaciones en un rango de 30 km y tercero reduciendo la distancia mínima necesaria. El tercero solo se debe realizar si el primero y segundo no se puede cumplir.



5.2.5 Structure from motion (SfM):

Utilizando la salida de cámaras se obtiene la estructura 3D del entorno y el movimiento de la cámara [40]. Para realizar esto se sigue un número de pasos, detección de características, emparejamiento de características y estimación de pose y movimiento de la cámara, siendo las características generalmente la detección de puntos de referencia.

Los avances en esta tecnología empezaron con la introducción de métodos basados en formalismo y factorización siendo el primero a considerar el más tarde denominado Algoritmo de 8 puntos por H. C. Longuet-Higgins el cual por método lineal en correspondencia de puntos soluciono el problema de SfM para cámaras. Luego se mejoró por R. I. Hartley. Otros métodos como el método de factorización por C. Tomasi y T. Kanade fue mejorado por P. F. Sturm y B. Triggs. A continuación, está la Tabla 25 de [42] con estos y varios avances de gran importancia:

Método	Autor	Año	Título
Lineal	H.C. Longuet-Higgins	1981	A computer algorithm for reconstructing a scene from two projections.
Factorización	C. Tomasi; T. Kanade	1992	Shape and motion from image streams under orthography: A factorization method.
	P. F. Sturm; B. Triggs	1996	A factorization-based algorithm for multi-image projective structure and motion.
Lineal	R. I. Hartley	1997	In defence of the eight-point algorithm.
Factorización	T. Kanade; D. Morris.	1998	Factorization methods for structure from motion.
Estimación de la ubicación de la cámara	V. M. Govindu	2001	Combining two-view constraints for motion estimation.
	M. Brand et al.	2004	Spectral solution of large-scale extrinsic camera calibration as a graph embedding problem.
Promedio iterativo	V. M. Govindu	2004	Lie-algebraic averaging for globally consistent motion estimation.
Convexo robusto	O. Ozyesil et al.	2015	Robust camera location estimation by convex programming.
Estimación de la ubicación de la cámara	A. Chatterjee et al.	2013	Efficient and robust large-scale rotation averaging.
	K. Wilson; N. Snavely	2014	Robust global translations with 1DSfM.
	R. Tron; R. Vidal	2014	Distributed 3-D localization of camera sensor networks from 2-D image measurements.
	O. Ozyesil et al.	2015	Stable camera motion estimation using convex programming.
Convexo robusto	T. Goldstein et al.	2016	ShapeFit and ShapeKick for robust, scalable structure from motion.



Estimación de tres pasos	F. Arrigoni	2016	Camera motion from group synchronization.
Convexo robusto	P. Hand et al.	2017	ShapeFit: Exact location recovery from corrupted pairwise directions.

Tabla 25: “Evolución de SfM” [42]

Existen actualmente cuatro algoritmos principales de detección de características [40], estos siendo el detector Harris Corner, SIFT, SURF y KTS. Según el artículo X los dos mejores son el SIFT y KTS ya que tienen un menor error para la rotación y traslación. Después de los experimentos se determina que el mejor para el uso en vehículos es el algoritmo SIFT.

Para la inspección a realizar, se enviarán por cable ethernet imágenes de referencia al hardware del vehículo donde estará alojado el algoritmo de SFM. Observando la salida desde el hardware de los datos del SFM se obtienen primero los valores de traslación en el eje x e y. Luego sabiendo que la comparación directa de puntos detectados es el enfoque inadecuado por lo que comparamos las diferencias en la geometría epipolar (geometría de la visión estéreo) utilizando la matriz fundamental estimada para llegar al error de reproyección. Teniendo un menor error de reproyección nos acerca más al valor de referencia y utilizamos esta salida en conjunto con la distancia promedia del punto real para realizar la comparación.

5.3 Unidad computacional (Hardware):

El hardware consiste en el elemento computacional para procesar los datos de los sensores y realizar la toma de decisiones. Su forma física se parecería a una placa de circuito integrado con diferentes componentes como el procesador (CPU), memoria de acceso aleatorio (RAM), tarjeta gráfica GPU y varios sistemas en chip (SoC) teniendo un parecido razonable con una computadora personal.

Gracias a esta similitud, diferentes fabricantes de vehículos autónomos utilizan hardware producido por terceros, aunque en algunas excepciones como la marca Tesla se realiza su creación internamente [8, 9].

Por el otro lado, en este componente se realizan todas las operaciones necesarias en tiempo real para los pasos de detección, clasificación, predicción y toma de decisiones siendo todos estos confinados a diferentes algoritmos trabajando en sincronía. Siendo este el caso, para revisar el correcto funcionamiento de este elemento de manera física y digital en forma de algoritmos, se le debe someter a una prueba completa en el cual todas estas partes se inspeccionan a la vez. Esto implica que el fallo de una parte durante dicha inspección compromete todo el proceso de conducción, salvo los sensores y comunicaciones los cuales se inspeccionan por separado. Pero se debe recalcar que este acercamiento es necesario ya que, si solo una parte falla en el proceso, toda la conducción autónoma puede sufrir errores catastróficos durante su operación en el tráfico general.

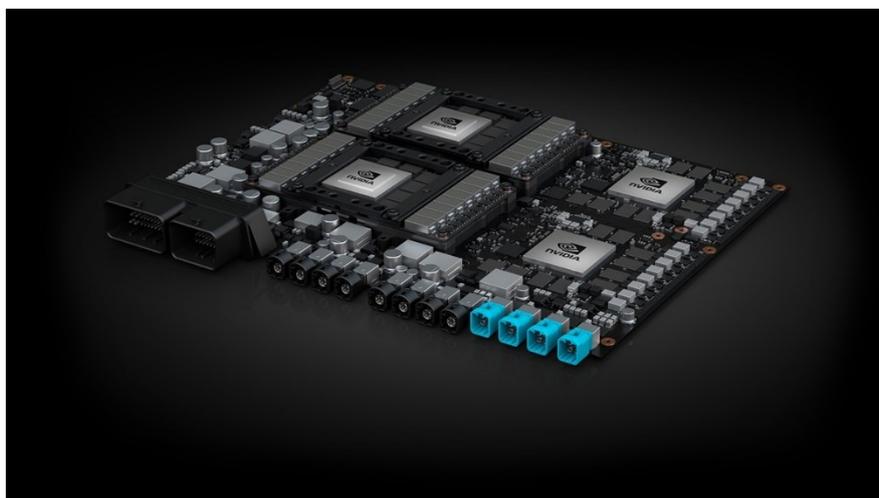


Fig. 13: “Hardware de vehículos de conducción autónoma” [Online]. Disponible en: <https://www.nvidia.com/es-es/self-driving-cars/drive-platform/hardware/>. [Accedido en: 3-Jun-2022].



Las tecnologías y avances para este componente del vehículo seguían las capacidades de manufacturación de SoCs, CPUs, RAMs y GPUs cada vez más sofisticados. Muchos fabricantes electrónicos ya ofrecen soluciones de unidad computacional compactas dedicadas al control de vehículos autónomos. Aunque los mismos procesos se pueden realizar en un ordenador personal, esto no es posible implementarlo debido al reducido espacio disponible en el interior de un vehículo. Algunas de ellas son utilizando [43]:

- **NVIDIA DRIVE AGX:** Es un System-on-Chip (SoC) y consiste en dos núcleos Xavier con cada uno teniendo un CPU de 8 núcleos personalizado y un Volta GPU de 512 núcleos. Es capaz de 320 trillones de operaciones por segundo (TOPS).
 - **Zynq UltraScale+ MPSoC ZCU104:** Producto de Xilinx está basado en FPGA diseñado para conducción autónoma. Contiene un ARM Cortex-A53 de 64 bits cuatro núcleos y un ARM Cortex-AR5 de doble núcleo. Corriendo trabajos de CNN llega a 14 imágenes/seg/vatio. También para seguimiento de objetos llega a 60 fps en vídeo en directo de 1080p.
 - **TDA3x SoC (Texas Instruments TDA):** Solución DSP realizada con dos C66x Floating-Point VLIW DSP núcleos y visión AccelerationPac. Además, cada TDA3x SoC tiene doble Arm Cortex-M4 procesador de imágenes. El acelerador de visión está diseñado para acelerar la función de procesos en imágenes.
 - **EyeQ5 (MobilEye):** Solución ASIC para vehículos de automatización nivel 5. Está basado en la tecnología de semiconductor 7nm-FinFET y proporciona una potencia computacional de 24 TOPS por 10 vatios.
 - **TPU (Google):** Es un acelerador AI basado en ASIC para red neuronal y aprendizaje automático. La última es TPU v3 con potencia computacional de 420 TFLOPS.
- NVIDIA DRIVE AGX: Es un System-on-Chip (SoC) y consiste en dos núcleos Xavier con cada uno teniendo un CPU de 8 núcleos personalizado y un Volta GPU de 512 núcleos. Es capaz de 320 trillones de operaciones por segundo (TOPS).

Por ello, para revisar su correcto funcionamiento se debe ver si todos los componentes electrónicos controlados por el hardware funcionan correctamente. Aparte de los paneles e interfaces de interacción disponibles para un conductor, se debe observar si induciendo el vehículo a realizar diferentes tipos de maniobras, girar ruedas, frenar, acelerar etc. estos son completados con éxito. Esto se conseguirá con unas salidas de sensores conocidas de antemano, sabiendo que tipo de respuesta este debe generar en el vehículo.

Sabiendo que la disposición y tipo de los sensores es diferente para cada modelo de coche, se deben utilizar salidas de sensores de referencia únicos para cada uno. Con el posible incremento de dichos modelos y la casi infinita variedad de instalación de los componentes, se necesitará obtener estas salidas de los sensores de referencia de un organismo externo pero fiable. Suponiendo que antes de la aprobación para circulación de dichos modelos de coches estos deben ser aprobados por los organismos pertinentes, durante las inspecciones para la mencionada aplicación se recolectarán datos de las salidas de todos los sensores. Las imágenes y datos de LiDAR, radar y cámaras que se toman cuando se aprueban los vehículos para circulación en España, se envían a los talleres de ITV para ser utilizados en sus inspecciones. Con estos datos, se tendrán las salidas de cada sensor y las respuestas que esperamos que el vehículo tome en dichas situaciones. Esto aligera el trabajo del ITV considerando que para cada configuración diferente de sensores que presenta cada modelo de coche tendremos una base de datos aplicable y fiable.

La utilización de esta base de datos será simple. Bajo el vehículo a testear tendremos una cinta omnidireccional en la que el coche puede girar sus ruedas sin que se mueva fuera de ella. Esto también añade el beneficio de poder observar las direcciones en el que se mueve dicha cinta, obteniendo la ruta exacta que toma el coche considerando la asunción de que la cinta solo se mueve si el vehículo se mueve.

De esta forma, enviamos directamente las salidas conocidas a la unidad computacional del vehículo para que este se mueva en la ruta esperada. Al moverse sobre la cinta, observaremos los ángulos de giro, velocidades, dirección



y tiempo de respuesta asignando una puntuación basada en ello. La puntuación se basará en el que ha sido utilizado por el comité para la aprobación de vehículos autónomos en España.

Por último, la detección electrónica consistiría en medir valores de voltaje e intensidad en puntos de prueba en la placa designados por el fabricante. Estos puntos se observarán manualmente con un multímetro accediendo físicamente a la placa.

También hay que mencionar que dependiendo de la localización de la unidad computacional es quizás imposible acceder a ella para esta prueba.

5.4 Drive by wire (Conexiones):

Drive by wire cumple la función principal de ejecutar de forma correcta los órdenes de movimiento longitudinal y lateral del vehículo cuando éste es controlado por el sistema autónomo. Se compone de cables de conexión eléctrica, actuadores y controles del vehículo tradicionales (control de eje, torque, etc.) [50].

Si todos los elementos electrónicos (sensores, comunicaciones, hardware etc.) anteriormente inspeccionados devuelven resultados dentro de los límites establecidos, se considera que las conexiones internas y externas electrónicas funcionan correctamente. Esto se realiza así ya que durante la inspección del hardware observamos el movimiento de las ruedas, sus ángulos y la velocidad de rotación de estas. Esto es controlado a través de las conexiones y por ello durante la prueba del hardware también inspeccionamos el drive by wire.

6. REQUISITOS PARA INSTALACIONES

Para la realización de inspección de los diferentes elementos de un vehículo con capacidad de conducción autónoma, se necesitan instalaciones especiales en los talleres de ITV.

6.1 Plataforma de sujeción de sensores:

Consiste en una plataforma colgante desde el techo del edificio, posicionándose por encima del vehículo a inspeccionar. Esta plataforma debe estar a una altura de 4 metros sobre el suelo consistiendo en 4 raíles en forma de rectángulo con una superficie central, siendo todo esto fijado al techo con una estructura rígida de metal. Sobre los raíles deben posicionarse los sensores de cámaras en una disposición de que vean los mismos elementos que los sensores del vehículo, estando 4 de ellos en el centro de cada rail y 4 en cada esquina. Para este objetivo, el Radar y LiDAR se posicionan en el centro del rectángulo boca abajo no siendo obstruidos de ninguna forma por los otros sensores. Su localización les permite realizar barridos en 360° pudiendo observar todo el taller.

Otro elemento sobre el riel debe estar en su rail frontal (punto de vista del vehículo a inspeccionar), teniendo en la parte frontal otra cámara aparte del simple. Este debe ser de tipo estéreo capaz de imágenes 3D. Esta disposición ayuda a observar los mismos elementos que las cámaras frontales del vehículo y el FoV de las cámaras debe asegurar que existe solapamiento entre ellas en todas las instancias.

6.2 Unidad computacional:

Las salidas de los sensores irían directamente conectadas a ellas y por ello debe ser capaz de realizar un elevado número de operaciones a gran velocidad teniendo en cuenta que se trabajarán en 2 sensores a la vez. Su forma será de un ordenador de alta capacidad con posibilidad de múltiples entradas de ethernet y programas de algoritmo capaz de operar con todos los sensores para detección y clasificación de objetos. Considerando la importancia de la rapidez en la duración de las inspecciones, se recomienda una unidad con suficiente capacidad computacional para realizar las operaciones en tiempo real para dos entradas al mismo tiempo. Sabiendo la importancia de la simultaneidad de los cálculos sobre las entradas de referencia y el del vehículo a inspeccionar, esto se asegura utilizando solo un ordenador de procesamiento y esperando antes de cada cálculo para asegurarse que los dos se realicen al mismo tiempo.



Siguiendo las especificaciones utilizadas en [el de cámara] donde se realizaba detección de objetos y clasificación para una entrada, en nuestro caso se necesitará estos requisitos o superior:

- CPU: 32 núcleos, 64 hilos y 3.7 GHz (Ej.: AMD Threadripper 3970X o similar)
- GPU: 24 GB GDDR6, ancho de banda 936 GB/s y bus de memoria 384 bits (Ej.: Nvidia GeForce RTX 3090 o similar)
- RAM: 32 GB DDR5
- Placa base: Capaz de alojar todos los componentes.
- Fuente de alimentación: 650 W o superior

6.3 Cámaras:

Cómo se mencionó con anterioridad, se necesitarán 8 cámaras convencionales de medio alcance (aproximadamente 60 metros) y una cámara estéreo compuesta por la integración de dos o más cámaras en un sistema. Las 8 cámaras irán en cada esquina y lado de la estructura y la cámara estéreo mirará hacia delante. Cada una de estas cámaras deberá tener un amplio FoV para solaparse uno con el otro e ir conectada a un sensor de imagen. También se debe notar la necesidad de instalarlo con un ángulo necesario para observar todos los objetos visibles en el área de inspección (Ej.: -30°). Utilizando los estudios sobre las cámaras en los vehículos Tesla y Audi y apuntando por características superiores, necesitamos estos requisitos o superiores:

- Cámara simple: resolución 2896 x 1876 (5.4 MP) a 40 cuadros por segundo (FPS), rango 10 metros mínimo y FoV 70° Vertical, 120° Horizontal (Ej.: Waveshare IMX179 8MP USB Camera)
- Sensor de imagen: resolución 2896 x 1876 CMOS, microcontrolador de 12-bits, 40 FPS, 120 dB alto rango dinámico (HDR) y sensibilidad 2280 mV (Ej.: Sony IMX490 [44] o similar)
- Cámara estéreo: resolución 3D 1216 x 1024 (1.25 MP) a 30 FPS, rango 10 metros mínimo, FoV 70° vertical y 80° horizontal. (Ej.: Nerian Scarlet 3D Depth Camera [45])

6.4 LiDAR:

Se tendrá un único LiDAR montado en el centro de la estructura boca abajo con el objetivo de escanear todo el suelo y objetos presentes en el área de inspección en 360°. No importa la tecnología de giro en este caso ya que no hay restricciones de tamaño. Considerando el LiDAR utilizado en el Audi A8 se requiere tener estas especificaciones o superiores:

- LiDAR: Rango 50 metros mínimo, FoV horizontal 360°, longitud de onda 900 nm, 32 canales y precisión de ± 3 cm. (Ej.: Velodyne Lidar Ultra Pluck [46])

6.5 Radar:

El radar de inspección irá montado en el centro de la plataforma de sujeción posicionado para detectar los objetos debajo de él. El objetivo es la utilización de un solo radar con visión 360° y rango suficiente para observar la totalidad del área de trabajo.

Para la selección de características mínimas se utilizarán el punto de partida de radares utilizados en otros vehículos autónomos con radares como el Continental ARS4-B y Bosch LRR4. Debido a la inexistencia de restricciones de tecnologías y construcciones se pueden emplear cualquier modelo mientras se cumplan o superen las restricciones siguientes:

- Radar: Rango 50 metros mínimo, FoV horizontal 360°, antena de 6 canales y precisión de ± 0.13 m. (Ej.: ART Midrange [47])



6.6 Cables Ethernet:

Número necesario de cables para conectar tanto los sensores de referencia como los sensores del vehículo a la unidad computacional para enviar las señales. También se necesita otro cable para la transmisión de salidas de la unidad computacional del taller ITV a la del vehículo a inspeccionar.

6.7 Gafas de protección:

Gafas de protección obligatorias para todos los técnicos que trabajarán en el área de operación del LiDAR. Esto es con el objetivo de eliminar el peligro por deslumbramiento al láser.

6.8 Cinta omnidireccional:

Con el objetivo de realizar la inspección de los componentes ADAS, este elemento facilita el movimiento omnidireccional del vehículo sin trasladarse fuera de él. Compuesto por multitud de sensores de detección de la dirección, al moverse el vehículo la cinta omnidireccional anotará los movimientos verticales y horizontales para inspección por la unidad computacional. Sabiendo los valores necesarios se puede realizar la inspección del hardware.

- Dicha cinta debe poder soportar como mínimo 3500 kg, ya que el SUV más pesado está a 3000 kg.
- Moverse en todas las posibles direcciones.
- Tener una precisión a la hora de grabar los movimientos de 0.1.
- Tamaño mínimo de 8 metros de largo y 4 metros de ancho.

7. PRESUPUESTO DE INSTALACIÓN

Sabiendo los elementos que se necesitan para el funcionamiento de una estación ITV de este tipo, se procede a presentar el presupuesto predicho, suponiendo 10 metros de altura media en un taller ITV:

Concepto	Cantidad	Unidad	Valor	Total
Materiales				
AMD Threadripper 3970X [51]	1	u	2699,99 €	2699,99 €
Nvidia GeForce RTX 3090 [52]	1	u	2058,25 €	2058,25 €
Kingston 16 GB DDR5 4800MHz [53]	2	u	99,99 €	199,98 €
Placa base Gigabyte B560M DS3H V2 [54]	1	u	95,47 €	95,47 €
Fuente de alimentación 650 W [55]	1	u	91,63 €	91,63 €
Waveshare IMX179 8MP USB Camera [56]	8	u	49,99 €	399,92 €
Sony IMX490 [57]	8	u	138,25 €	1106 €
Nerian Scarlet 3D Depth Camera	1	u	13900 €	13900 €
Velodyne Lidar Ultra Pluck [58]	1	u	500 €	500 €
ART Midrange	1	u	1200 €	1200 €
Cable Ethernet [59]	12	m	0,4 €	4,8 €
Acero S235JR conf frío acab galv [60]	35	kg	1,19 €	41,65 €
Cinta omnidireccional	1	u	Indeterminado	Indeterminado
Gafas de protección AGETECH 1271-SafeLightPro [61]	3	u	16,61 €	49,83 €
Cbl pares red dt UTP ctg 6 nor [62]	40	m	0,75 €	30 €
Sub total				22377,52 €



Mano de obra				
Oficial 1º metal [60]	6	h	18,49 €	110,94 €
Especialista metal [60]	6	h	15,71 €	94,26 €
Oficial 1º electricidad [60]	6	h	18,49 €	110,94 €
Peón electricidad [60]	6	h	14,71 €	88,26 €
Programación, config y puesta en marcha [60]	2	h	61,2 €	122,4 €
Sub total				526,8 €
Total General				22904,32 €

8. PROCEDIMIENTO DE INSPECCIÓN

La estructura del siguiente apartado combina la información anteriormente expuesta para crear una organización similar al utilizado en el documento técnico de inspecciones ITV. De ese modo se sigue la distribución de la misma, separando cada elemento a observar en apartados individuales. Por ello cada apartado presenta unas especificaciones generales del elemento, explicando las necesidades generales y obligatorias a cumplir. Después se describe el método de realización de la inspección del elemento, debiendo seguir los pasos descritos en el orden de presentación. Por último, habiendo realizado la inspección se procede a la interpretación de defectos para anotar si los fallos observados caen en la denominación de daño leve, grave o muy grave. Considerando el supuesto de que todos los vehículos inspeccionados pueden cambiar a control manual, sólo los defectos los cuales inhabilitan este son clasificados como daño grave y necesitan el transporte por grúa.



7.1 Cámaras

Especificaciones generales:

Obligatoria en vehículos de automatización 2.5 o superiores a excepción de tener sensores de similar capacidad para las funciones de detección y clasificación de objetos. También es obligatorio tener un puerto de salida para realizar la inspección del ITV.

Número y disposición de las cámaras mínimas de obligado cumplimiento:

- Un dispositivo obligatorio para cada lado del vehículo teniendo un alcance mínimo de 60 metros.
- Una cámara frontal estéreo.
- Una cámara frontal de largo alcance (200 metros).

Método:

Mediante inspección visual se comprobará:

- El número de cámaras en relación con el modelo de fábrica.
- El estado físico del cuerpo de plástico observando roturas, desplazamientos e inconsistencias a la disposición ideal de fábrica.
- El estado físico de las lentes observando fracturas, arañazos y falta del elemento.
- La homologación
- El estado de la montura, en caso de disponerlo.
- El funcionamiento del testigo para observar si se enciende en caso de fallo del componente.

Mediante inspección digital se siguen estos pasos:

- Se posiciona una señal de tráfico (su tipo no afecta la inspección) y un muñeco de tamaño humano en los cuatro lados del vehículo a inspeccionar para asegurar la existencia de objetos a detectar.
- Se conecta una cámara individual, del vehículo a inspeccionar, al ordenador de estudio utilizando un cable ethernet.
- Se conecta la cámara de referencia al ordenador de estudio, montado en la plataforma, el cual corresponde a la misma dirección que observa el sensor del vehículo. La conexión es por cable ethernet.
- Se recorta de manera automática, utilizando un programa, la imagen de salida de la cámara de referencia para ajustarse al FOV de la cámara del vehículo y observar la misma área. Esto se puede realizar si se conoce de antemano el modelo del vehículo y la posición y capacidad de sus cámaras
- El técnico observa la salida de las cámaras para observar que la imagen en las dos representa el mismo espacio de estudio.
- Se inicia el programa de detección de objetos para las dos cámaras de manera simultánea
- Después de una tener el programa iniciado como mínimo 3 minutos, se concluye la inspección y se comparan los resultados de las detecciones medias entre la cámara de referencia y la del vehículo. Este valor representa la diferencia de elementos detectados por las dos cámaras.
- El procedimiento se repite desde el principio tantas veces como sensores de cámaras tenga el vehículo a inspeccionar.



Interpretación de defectos:

Descripción de defecto	Calificación		
	DL	DG	DMG
1.- Número de cámaras no reglamentaria		x	
2.- Rotura o defecto visible en el cuerpo de la cámara	x		
3.- Posición no reglamentaria de alguna cámara		x	
4.- Cámara no homologada		x	
5.- Rotura o desplazamiento de la montura	x		
6.- Rotura o defecto en las lentes de la cámara			
6.1.- El defecto cubre menos del 50% del lente	x		
6.2.- El defecto cubre más del 50% del lente		x	
7.- No funciona alguna cámara o no envía señales por su salida			
8- Diferencia de valores de precisión promedia (AP) entre la cámara del vehículo y la de referencia			
8.1.- La diferencia es entre 2% y 3%	x		
8.2.- La diferencia es mayor a 3%		x	
9.- Funcionamiento incorrecto del testigo de esta pieza en caso de disponerlo	x		



7.2 LiDAR

Especificaciones generales:

En caso de la existencia de un sensor LiDAR en el vehículo a inspeccionar, uno de ellos debe al menos estar posicionado por encima o debajo del capó delantero observando el frente. También es obligatorio tener un puerto de salida para realizar la inspección del ITV.

Método:

Mediante inspección visual se comprobará:

- El número de LiDARs en relación con el modelo de fábrica.
- El estado físico del cuerpo de plástico observando roturas, desplazamientos e inconsistencias a la disposición ideal de fábrica.
- El estado físico de los cristales de salida del haz de láser, observando fracturas, arañazos y falta del elemento.
- La homologación
- El estado de la montura, en caso de tenerlo.
- El estado de la plataforma giratoria en azimut, en caso de tenerlo.
- En caso de ser de tipo de rotación mecánica, observar que durante la inspección digital realiza todos los movimientos sin problema.
- El funcionamiento del testigo para observar si se enciende en caso de fallo del componente.

Mediante inspección digital se siguen estos pasos:

- Se posiciona una señal de tráfico (su tipo no afecta la inspección) y un muñeco de tamaño humano en los cuatro lados del vehículo para asegurar la existencia de objetos a detectar.
- Se conecta un LiDAR individual, del vehículo a inspeccionar, al ordenador de estudio utilizando conexión ethernet.
- Se conecta el LiDAR de referencia al ordenador de estudio, montado en la plataforma asegurándose que tiene una visión de 360° sin obstrucciones.
- Se recorta de manera automática la salida, utilizando un programa, la nube de puntos de salida del LiDAR de referencia para ajustarse al FOV del LiDAR del vehículo y observar la misma área. Esto se puede realizar si se conoce de antemano el modelo del vehículo y la posición y capacidad de sus sensores
- El técnico observa la salida de los LiDARs para comprobar que la imagen en las dos representa el mismo espacio de estudio.
- Se inicia el programa de detección de objetos para los dos LiDARs al mismo tiempo.
- Después de una tener el programa iniciado como mínimo 3 minutos, se concluye la inspección y se comparan los resultados de las detecciones medias entre el LiDAR de referencia y la del vehículo. Este valor representa la diferencia de elementos detectados por los dos LiDARs.
- El procedimiento se repite desde el principio tantas veces como sensores de LiDAR se tengan en el vehículo a inspeccionar.



Interpretación de defectos:

Descripción de defecto	Calificación		
	DL	DG	DMG
1.- Número de LiDARs no reglamentaria		x	
2.- Rotura o defecto visible en el cuerpo del LiDAR	x		
3.- Posición no reglamentaria de algún LiDAR		x	
4.- LiDAR no homologada		x	
5.- Rotura o desplazamiento de la montura	x		
6.- Plataforma giratoria defectuosa (por inspección visual)		x	
7.- No funciona algún LiDAR o no envía señales por su salida		x	
8.- No es capaz de realizar movimientos en el azimut o eje vertical		x	
9.- Diferencia de valores de precisión promedia (AP) entre el LiDAR del vehículo y la de referencia			
9.1.- La diferencia es entre 2% y 5%	x		
9.2.- La diferencia es mayor a 5%		x	
10.- Funcionamiento incorrecto del testigo de esta pieza en caso de disponerlo	x		



7.3 Radar

Especificaciones generales:

En caso de la existencia de un sensor Radar en el vehículo a inspeccionar, uno de ellos debe al menos estar posicionado por encima o debajo del capó delantero observando el frente. También es obligatorio tener un puerto de salida para realizar la inspección del ITV.

Método:

Mediante inspección visual se comprobará:

- El número de Radares en relación con el modelo de fábrica.
- El estado físico del cuerpo de plástico observando roturas, desplazamientos e inconsistencias a la disposición ideal de fábrica.
- El estado físico de los cristales de salida de la onda de radiofrecuencia, observando fracturas, arañazos y falta del elemento.
- La homologación
- El estado de la montura, en caso de tenerlo.
- El estado de la plataforma giratoria en azimut, en caso de tenerlo.
- El funcionamiento del testigo para observar si se enciende en caso de fallo del componente.

Mediante inspección digital se siguen estos pasos:

- Se posiciona una señal de tráfico (su tipo no afecta la inspección) y un muñeco de tamaño humano en los cuatro lados del vehículo para asegurar la existencia de objetos a detectar.
- Se conecta un Radar individual, del vehículo a inspeccionar, al ordenador de estudio utilizando conexión ethernet.
- Se conecta el Radar de referencia al ordenador de estudio, montado en la plataforma asegurándose que tiene una visión de 360° sin obstrucciones.
- Se recorta de manera automática la salida, utilizando un programa, la nube de puntos de salida del Radar de referencia para ajustarse al FOV del Radar del vehículo y observar la misma área. Esto se puede realizar si se conoce de antemano el modelo del vehículo y la posición y capacidad de sus sensores
- El técnico observa la salida de los Radares para comprobar que la imagen en las dos representa el mismo espacio de estudio.
- Se inicia el programa de detección de objetos (combinación de Point Net++ + DBSCAN + LSTM) para los dos Radares al mismo tiempo.
- Después de una tener el programa iniciado como mínimo 3 minutos, se concluye la inspección y se comparan los resultados de las mAP y LAMR entre el Radar de referencia y la del vehículo. Este valor representa la diferencia de elementos detectados por los dos Radares.
- El procedimiento se repite desde el principio tantas veces como sensores de Radares se tengan en el vehículo a inspeccionar.



Interpretación de defectos:

Descripción de defecto	Calificación		
	DL	DG	DMG
1.- Número de Radares no reglamentaria		x	
2.- Rotura o defecto visible en el cuerpo del Radar	x		
3.- Posición no reglamentaria de algún Radar		x	
4.- Radar no homologada		x	
5.- Rotura o desplazamiento de la montura	x		
6.- No funciona algún Radar o no envía señales por su salida		x	
7- Diferencia de valores del promedio medio de precisión (mAP) entre el Radar del vehículo y la de referencia			
7.1.- La diferencia es entre 3% y 8%	x		
7.2.- La diferencia es mayor a 8%		x	
8- Diferencia de valores de la tasa promedio de fallas (LAMR) entre el Radar del vehículo y la de referencia			
8.1.- La diferencia es entre 3% y 5%	x		
8.2.- La diferencia es mayor a 5%		x	
9.- Funcionamiento incorrecto del testigo de esta pieza en caso de tenerlo	x		



7.4 GPS

Especificaciones generales:

Obligatoria en vehículos de automatización 2.5 o superiores con un componente electrónico, otro de control para el usuario en su panel de control y con puertos de salida al componente para el objetivo de inspecciones. La posición del elemento y tecnología mínima no está regulada y está a disposición del fabricante.

Método:

Mediante inspección visual se comprobará:

- El estado físico del cuerpo de plástico observando roturas, desplazamientos e inconsistencias a la disposición ideal de fábrica si es visible el componente.
- La homologación
- El estado de la montura, en caso de tenerlo.
- Posicionado el vehículo exactamente en el punto de inspección, se observarán las coordenadas exactas del GPS. Esto puede realizarse directamente, utilizando los paneles de control del mismo vehículo o conectando un dispositivo externo para ello.
- El funcionamiento del testigo para observar si se enciende en caso de fallo del componente.

Interpretación de defectos:

Descripción de defecto	Calificación		
	DL	DG	DMG
1.- Rotura o defecto visible en el cuerpo del GPS	x		
2.- GPS no homologada		x	
3.- Rotura o desplazamiento de la montura	x		
4.- No funciona o no envía señales por su salida		x	
5.- No se recibe señal del satélite		x	
6- Diferencia entre las coordenadas de referencia y el del GPS:			
6.1.- La diferencia es entre 10 y 25 cm	x		
6.2.- La diferencia es mayor a 25 cm		x	
7.- Funcionamiento incorrecto del testigo de esta pieza en caso de tenerlo	x		



7.5 Comunicación vehículo-todo (V2X)

Especificaciones generales:

Obligatoria en vehículos de automatización 3 o superiores, debiendo tener la capacidad de comunicación V2X con la infraestructura en España y otros vehículos aprobados por el estado. También es obligatorio tener puertos de entrada y salida para la realización de transmisión y recepción de señales de inspección.

Método:

Mediante inspección visual se comprobará:

- El estado físico de la antena.
- El estado físico del cuerpo de plástico de los elementos SDR, GNSS y procesador del V2X.
- El estado físico de las conexiones por cable en caso de ser visible.
- La homologación
- El estado de la montura, en caso de disponerlo para la antena y el cuerpo del V2X.
- El funcionamiento del testigo para observar si se enciende en caso de fallo del componente.

Mediante inspección de radiocomunicación, se siguen estos pasos en caso de que el vehículo utiliza ITS-G5:

- Se conecta el procesador del V2X del vehículo al ordenador de estudio por cable ethernet.
- Se prepara un interfaz de red de referencia (RSU) el cual enviará su paquete por una antena.
- Primero se testea la difusión de datos de las comunicaciones a inspeccionar (procesador V2X).
- Utilizando la banda ITS de 5,9 MHz, se envían los mensajes normalizados de Mensaje de Atención Cooperativa (CAM), Mensaje de Notificación Ambiental Descentralizado (DENM) y Mensaje de Información de Infraestructura a Vehículo (IVIM)
- Luego se utiliza un programa (Ej.: CAMINO) para manejar, almacenar los datos recibidos y enviados, y postprocesar para obtener las métricas del ratio de paquetes entregados (PDR), ratio de paquetes perdidos y latencia extremo a extremo de una dirección (E2E).
- Se repite el proceso al revés, enviando los paquetes por RSU y recibiendo en el procesador de V2X del vehículo para manejar, almacenar y postprocesar ahí.

Mediante inspección de radiocomunicación, se siguen estos pasos en caso de que el vehículo utiliza C-V2X (PC5, 4G, 5G):

- Se conecta el procesador del V2X del vehículo al ordenador de estudio por cable ethernet.
- Se prepara un interfaz de red de referencia (RSU) el cual enviará su paquete por una antena.
- Primero se testea la difusión de datos de las comunicaciones a inspeccionar (procesador V2X).
- Utilizando la banda ITS de 5,9 MHz, se envían los mensajes normalizados de Mensaje de Atención Cooperativa (CAM), Mensaje de Notificación Ambiental Descentralizado (DENM) y Mensaje de Información de Infraestructura a Vehículo (IVIM)
- Luego se utiliza un programa (Ej.: CAMINO) para manejar, almacenar los datos recibidos y enviados, y postprocesar para obtener las métricas del ratio de paquetes entregados (PDR), ratio de paquetes perdidos y latencia extremo a extremo de una dirección (E2E).
- Se repite el proceso al revés, enviando los paquetes por RSU y recibiendo en el procesador de V2X del vehículo para manejar, almacenar y postprocesar ahí.



Interpretación de defectos:

Descripción de defecto	Calificación		
	DL	DG	DMG
1.- Antena dañada, imposibilitando transmisión y recepción		x	
2.- Rotura o defecto visible en el cuerpo del SDR, GNSS o procesador del V2X.	x		
3.- Rotura o defecto visible de las conexiones entre la antena y el SDR.	x		
4.- Posición no reglamentaria de la antena		x	
5.- Rotura o desplazamiento de la montura de la antena	x		
6.- No funciona la comunicación V2X o no envía señales por su salida		x	
7.- El ratio de paquetes entregados es inferior a 96%, a distancia mínima de 5 m con ITS-G5		x	
8.- El ratio de paquetes perdidos es superior a 5%, la distancia mínima de 5 m con ITS-G5		x	
9.- La latencia extrema a extremo de una dirección a percentil 90 es mayor a 3.5 ms con ITS-G5	x		
10.- El ratio de paquetes entregados es inferior a 98%, a distancia mínima de 5 m con C-V2X		x	
11.- El ratio de paquetes perdidos es superior a 5%, la distancia mínima de 5 m con C-V2X		x	
12.- La latencia extrema a extremo de una dirección a percentil 90 es mayor a 32 ms con C-V2X	x		
13.- Funcionamiento incorrecto del testigo de esta pieza en caso de disponerlo	x		



7.6 Unidad de medición inercial (IMU)

Especificaciones generales:

Obligatoria en vehículos de automatización 2.5 o superiores, debiendo tener instalado al menos uno de ellos en una ubicación a disposición del fabricante y puerto de salida para inspecciones. En caso de tener más de uno estos se deben posicionar en los ejes del automóvil.

Método:

Mediante inspección visual se comprobará:

- El estado físico del cuerpo de plástico en caso de ser visible.
- El estado físico de las conexiones por cable en caso de ser visible.
- La homologación
- El estado de la montura a las ruedas.
- El funcionamiento del testigo para observar si se enciende en caso de fallo del componente.

Mediante inspección dinámica se siguen estos pasos:

- Se conectan los IMUs al ordenador de estudio.
- Transformar las coordenadas del IMU al sistema de coordenadas preferente utilizando translación y rotación.
- Mediante el uso de pedales de marcha o rotando las ruedas manualmente, se avanza el vehículo sobre la CINTA DE CORRER. Conociendo la distancia recorrida y ángulos de giro.
- Al finalizar la prueba se frena el vehículo.

Interpretación de defectos:

Descripción de defecto	Calificación		
	DL	DG	DMG
1.- Rotura o defecto visible en el cuerpo del IMU.	x		
2.- Rotura o defecto visible de las conexiones del IMU	x		
3.- IMU no homologada		x	
4.- Rotura o desplazamiento de la montura del IMU.	x		
5.- Diferencia de más de 0,35 m en desplazamiento lateral o longitudinal respecto a la referencia.		x	
6.- Diferencia de más de 0.6° en la orientación respecto a la referencia.		x	
7.- Funcionamiento incorrecto del testigo de esta pieza en caso de disponerlo	x		



7.7 Localización y mapeo simultáneos (SLAM)

Especificaciones generales:

Algoritmo no obligatorio en caso de disponer de alternativas cumpliendo el mismo objetivo.

Método:

Mediante inspección digital se siguen estos pasos:

- Se conecta la unidad computacional (hardware) al ordenador de estudio.
- Se traspa el mapa creado por el SLAM al ordenador de estudio.
- Primero se selecciona la sección del mapa creado por el vehículo durante su acercamiento a la estación ITV, considerando el inicio de la sección a una distancia de 500 m. Si dicha sección del mapa tiene menos de X puntos de referencia o es posible que el acercamiento tenga más de una posible ruta se descarta.
- Si la sección anterior no cumple con las restricciones anteriormente impuestas, se selecciona una sección del mapa con carreteras generales (fuera de poblados), autovías o autopistas frecuentadas en las inmediaciones en un rango de 30 km con un mínimo de X puntos de referencia
- Si la sección anterior no cumple con las restricciones anteriormente impuestas, se reduce el rango de 500 m referente al acercamiento del ITV y el número de puntos de referencia necesarios hasta un límite mínimo de 100 m. La distancia y puntos se reducen hasta llegar a una solución satisfactoria.
- Con nuestra selección de la sección del mapa del vehículo a inspeccionar, se compara con el mapa de referencia creado con anterioridad observando las posiciones y número de puntos de referencia.

Interpretación de defectos:

Descripción de defecto	Calificación		
	DL	DG	DMG
1.- Número de pases realizados es superior a 100 para el rango o situación concreta.	x		
2.- Si el rango de acercamiento al ITV es de 500 m, alejamiento máximo de 0.7%.		x	
4.- Si se compara con secciones de carretera general, autovías o autopistas, alejamiento máximo de 0.8%.	x		
7.- Si el rango de acercamiento al ITV es entre 500 y 100 m, alejamiento máximo de 0.6%.		x	
8.- Funcionamiento incorrecto del testigo de esta pieza en caso de disponerlo	x		



7.8 Structure from motion (SfM)

Especificaciones generales:

Algoritmo no obligatorio en caso de disponer de alternativas cumpliendo el mismo objetivo.

Método:

Mediante inspección digital se siguen estos pasos:

- Se conecta la unidad computacional (hardware) al ordenador de estudio por cable ethernet.
- Se envían imágenes de referencia al hardware.
- Se conecta la salida del hardware al ordenador de estudio.
- Sacar los valores de traslación del eje x e y para ver error de traslación para los dos.
- Utilizando la matriz fundamental estimada para obtener el error de reproyección.
- Utilizando la geometría epipolar se obtiene la distancia epipolar en píxeles del punto real.

Interpretación de defectos:

Descripción de defecto	Calificación		
	DL	DG	DMG
1.- Error de traslación en el eje x mayor a 1.		x	
2.- Error de traslación en el eje y mayor a 0,5.		x	
3.- Error de reproyección mayor a 7,3.		x	
4.- La distancia epipolar al punto real es mayor a 10 píxeles.		x	
5.- Funcionamiento incorrecto del testigo de esta pieza en caso de disponerlo	x		



7.9 Unidad computacional (Hardware)

Especificaciones generales:

Obligatoria en vehículos de automatización 2 o superiores, con puertos de tipo ethernet de entrada y salida al componente para el objetivo de inspecciones. La posición del elemento y tecnología mínima no está regulada y está a disposición del fabricante.

Método:

Mediante inspección visual se comprobará:

- El funcionamiento del testigo para observar si se enciende en caso de fallo del componente.

Mediante inspección digital se siguen estos pasos:

- Se conecta la unidad computacional (hardware) al ordenador de estudio por cable ethernet.
- Se envían los datos de las salidas de sensores de referencia de la base de datos, correspondiente al modelo del vehículo.
- Estas salidas se envían uno a uno al hardware midiendo la distancia recorrida, velocidad, ángulo de giro y tiempo de reacción de la rueda sobre la cinta de correr. Estas mediciones se comparan con los valores esperados.
- Se repite el proceso para todos los sensores que el vehículo tenga.

Interpretación de defectos:

Descripción de defecto	Calificación		
	DL	DG	DMG
1.- Mayor distancia recorrida al esperado por 1 m		x	
2.- Velocidad de aceleración mayor a la esperada con 0.3 m/s		x	
3.- Velocidad de aceleración menor a la esperada con 0.3 m/s		x	
4.- Desviación del ángulo de giro al esperado por 1°		x	
5.- Tiempo de reacción entre el envío de la señal al hardware a la toma de acción por los actuadores mayor a 30 ms		x	
6.- Funcionamiento incorrecto del testigo de esta pieza en caso de disponerlo	x		



7.10 Drive by wire (Conexiones)

Especificaciones generales:

Obligatoria en vehículos de automatización con capacidad de manejo del movimiento longitudinal y lateral, velocidad y/o frenado del vehículo.

No es obligatorio una configuración o mecanismo específico para el accionamiento del control, pero debe seguir normas aprobadas para estas partes.

Método:

Mediante inspección visual se comprobará:

- El estado físico del mecanismo de accionamiento y uniones.
- El estado físico de las conexiones (elementos que conectan el accionador con la parte a controlar) por cable o mecánica en caso de ser visible.
- El funcionamiento del testigo el cual avisa de cualquier fallo de la pieza.

Interpretación de defectos:

Descripción de defecto	Calificación		
	DL	DG	DMG
1.- Rotura o defecto visible en el mecanismo de accionamiento y uniones.			x
2.- Rotura o defecto visible en las conexiones por cable o mecánica			x
3.- Funcionamiento incorrecto del testigo de esta pieza en caso de disponerlo	x		



9. CONCLUSIONES

In this environment of constant progress and innovation, it is important to set a baseline from which we can work and implement the improvements of tomorrow. With this end of degree project, I presented a study into the state of the art for ADAS systems and a technical guide to vehicle inspections providing the necessary depth and data with all the required foundation in order to understand the basics. For my point of view, it is important to keep in mind the advancements to always prevent security issues that could arise by spreading them to the civilian sector. On tool that is always used is limiting the scope of its spread so not that many users can get their hands on relevant technology, but this approach limits the investment that companies make to progress the relevant elements. This happens because if they can't see the way to make financial returns, the technology isn't developed to its full potential. For this reason, I made this project, so we can pre-emptively regulate the market so developers can know their limits to the products in development. This way we can foster an ever advancing tomorrow.

Likewise, in the autonomous car industry in Spain we have very restrictive regulations, only allowing research vehicles to operate in designated stretches of our roads stifling the market and investment which could be made in our own car industry (SEAT). If we could create the frame of restrictions and references which the car manufacturers will be able to follow for operating in our roads freely, there will be a feedback loop that creates more progress thanks to increased investment, and this progress will attract more costumers which will again create more interest by outside investors. However, for this to happen we need an extensive regulation and technical study into autonomous vehicles and their limits, and this project aims to abridge one element of this process by aiming for one of the more important parts of the security and reliability of the components for these systems. By revising and explaining the process of inspections for every element of an autonomous vehicle, we can signal to every manufacturer of the production process what limits we want to set to assure security in our roads.

On the other hand, this study only takes the theoretical in consideration because of time, budget and scope restraints which will need to be addressed. To demonstrate the validity of this proposed inspection model, it requires extensive field testing to ascertain the validity of the results that the sourced test arrived and discover unexpected problems or errors that this project may overlooked. This hypothetical practical study needs to encompass test into the practicality of the infrastructure proposed, algorithms employed, the required limits imposed in the interpretation of defects, possible better methods overlooked or developed after this project and recommendations made by the autonomous vehicle manufacturers. Taking into full consideration the knowledge that this kind of endeavour will need, their will need to be a multidisciplinary team which will support and amend shortcomings and considerations if every field of study. It's also recommended that this study be done by a governmental or third-party team so the results can be influenced by sources implicated in the manufacturing of any of the components or systems used for autonomous driving. This way we can assure that the results achieved will be well researched, fair and grounded in the realities that we live in.

In conclusion, although this extensive project touches and proposes many ideas, this proposition needs to be checked for their validity in the real world to determine the security and reliability, because at the end of the day vehicle inspections are indispensable to secure the lives of everyone on the roads.



10. APÉNDICE

Tabla 4: “Causas de fallos en las cámaras”

Fallo	Componente	Entrada / Salida	Efecto
Bandeado	Sensor de imagen	Luz / Imagen en bruto	Imagen alterada
Brillo	Lentes	Luz / Luz	Imagen alterada
Difuminado	Lentes	Luz / Luz	Imagen alterada
Efecto salobre (agua salada)	Lentes	Luz / Luz	Imagen alterada
	Cuerpo de la cámara	Luz / Nada	Sin imagen
Líneas brillantes	Sensor de imagen	Luz / Imagen en bruto	Imagen alterada
Rotura de lentes	Lentes	Luz / Luz	Imagen alterada
Rotura de regulación de vibración (VR)	Lentes	Luz / Luz	Imagen alterada
Condensación	Lentes	Luz / Luz	Imagen alterada
	Cuerpo de la cámara	Img. en bruto/ Nada	Sin imagen
Pixel muerto	Sensor de imagen	Luz / Imagen en bruto	Imagen alterada
Sucio	Lentes	Luz / Luz	Imagen alterada
Sobretensión eléctrica	Cuerpo de la cámara	Luz / Imagen	Imagen alterada
	Cuerpo de la cámara	Luz / Nada	Sin imagen
Llamarada	Lentes	Luz / Luz	Imagen alterada



Calor	Lentes	Luz / Luz	Imagen alterada
	Cuerpo de la cámara	Luz / Imagen	Imagen alterada
	Cuerpo de la cámara	Luz / Nada	Sin imagen
Hielo	Lentes	Luz / Luz	Imagen alterada
	Cuerpo de la cámara	Luz / Nada	Sin imagen
Sin acción	ISP	Img. en bruto/ Nada	Sin imagen
No filtro Bayer	Filtro Bayer	Luz / Imagen en bruto	Imagen alterada
Sin aberración cromática	ISP	Luz / Imagen en bruto	Imagen alterada
Sin interpolación cromática	ISP	Imagen en bruto / Imagen	Imagen alterada
Sin distorsión de lentes	ISP	Imagen en bruto / Imagen	Imagen alterada
Sin reducción de ruido	ISP	Imagen en bruto / Imagen	Imagen alterada
Sin nitidez	ISP	Imagen en bruto / Imagen	Imagen alterada
Lluvia	Lentes	Luz / Luz	Imagen alterada
Arena	Lentes	Luz / Luz	Imagen alterada
	Cuerpo de la cámara	Luz / Imagen	Imagen alterada
Manchas	Sensor de imagen	Luz / Imagen en bruto	Imagen alterada
Agua	Lentes	Luz / Luz	Sin imagen
	Cuerpo de la cámara	Luz / Nada	Sin imagen



Viento	Lentes	Luz / Luz	Imagen alterada
	Cuerpo de la cámara	Luz / Imagen	Imagen alterada

Tabla 4: “Causas de fallos en las cámaras”

Tabla 17 “Fallos en el Radar”

Componente	Causa del fallo	Parámetro alterado
Antenas fijas y en fase	<ul style="list-style-type: none"> ● Desajuste ● Daños en la guía de ondas de la antena 	<ul style="list-style-type: none"> ● Razón de onda estacionaria (VSWR) ● Parámetros de dispersión
Antenas parabólicas y su mecanismo de giro	<ul style="list-style-type: none"> ● Desajuste ● Daños en la guía de ondas de la antena ● Rodamientos 	<ul style="list-style-type: none"> ● VSWR ● Parámetros de dispersión ● Vibración
Cables de radiofrecuencia y sus conectores	<ul style="list-style-type: none"> ● Reflexión ● Corrosión ● Entrada de humedad ● Cambio de temperatura drástica 	<ul style="list-style-type: none"> ● Parámetros de dispersión ● Reflectometría de dominio de tiempo (TDR) ● Punto de intercepción de tercer orden (3IP)
Transceptores y unidad de medida de parámetros	<ul style="list-style-type: none"> ● Respuesta en fase ● Respuesta en frecuencia ● Linealidad ● Ganancia ● Adaptación de impedancia 	<ul style="list-style-type: none"> ● Tasa de error binario ● Fase ● Potencia / Voltaje ● Parámetros de dispersión ● 3IP
Radiotransmisor con transformador de alto voltaje	<ul style="list-style-type: none"> ● Razón de onda estacionaria ● Disipación de potencia ● Fuga de corriente 	<ul style="list-style-type: none"> ● Parámetros de dispersión ● VSWR ● Potencia ● Intensidad
Digitalización VLSI	<ul style="list-style-type: none"> ● Corriente de fuga del suministro ● Variación de corriente del suministro ● Firma de radar operación ● Ruido ● Variación de nivel lógico 	<ul style="list-style-type: none"> ● Voltaje ● Intensidad ● Fluctuación del retardo ● Distorsión
Procesador de señal digital y software asociado	<ul style="list-style-type: none"> ● Corriente de fuga del suministro ● Variación de corriente del suministro ● Firma de radar operación ● Ruido ● Variación de nivel lógico 	<ul style="list-style-type: none"> ● Voltaje ● Intensidad ● Fluctuación del retardo ● Distorsión
Unidad de visualización de video	<ul style="list-style-type: none"> ● Corrupción de imagen 	<ul style="list-style-type: none"> ● Voltaje



y procesador gráfico	<ul style="list-style-type: none"> visual Fluctuaciones del riel de alimentación 	<ul style="list-style-type: none"> Frecuencia de escaneo
Cables de datos digitales y conectores	<ul style="list-style-type: none"> Desgaste mecánico Corrosión Conexión suelta 	<ul style="list-style-type: none"> Continuidad TDR
Cables de control y conectores	<ul style="list-style-type: none"> Desgaste mecánico Corrosión Conexión suelta 	<ul style="list-style-type: none"> Continuidad TDR
Cables de potencia y conectores	<ul style="list-style-type: none"> Desgaste mecánico Corrosión Conexión suelta 	<ul style="list-style-type: none"> Continuidad TDR
Equipo de control ambiental	<ul style="list-style-type: none"> Temperatura excesiva Humedad 	<ul style="list-style-type: none"> Temperatura y humedad
Unidad de conversión DC/DC	<ul style="list-style-type: none"> Salida DC (nivel voltaje e intensidad) Rizado Ancho de pulso del ciclo de trabajo Eficiencia Retroalimentación (nivel de voltaje e intensidad) Fuga de corriente Ruido de radiofrecuencia 	<ul style="list-style-type: none"> Temperatura del transistor Eficiencia energética del transistor y razón de transferencia de corriente Perfil de temperatura Eficiencia energética y tensión de salida

Tabla 17: “Fallos en el Radar” [26]

Tabla 23: “Evolución de soluciones con sensores visuales”

Método	Construcción	Tecnología
Método directo	semiDenso	<ul style="list-style-type: none"> LSD-SLAM: (2014) por Jakob Enge et al. SVO: (2016) por Christian Forster et al. DSO: (2016) por Jakob Engel et al. EVO: (2016) por Henri Rebecq et al.
	Denso	<ul style="list-style-type: none"> DTAM: (2008) por Javier Civera et al. Kinect Fusion: (2011) por Richard A Newcombe et al. DVO: (2011) por Shahram Izadi et al. Kintinuuous: (2012) por Thomas Whelan et al. RGBD-SLAM-V2: (2013) por Felix Endres et al. RTAB-MAP: (2014) por Mathieu Labbe et al. Dynamic Fusion: (2015) por Richard A Newcombe et al. InfiniTAM: (2015) por O. Kähler et al. Elastic Fusion: (2016) por Matthias Innmann et al. MLM SLAM: (2016) por W Nicholas Greene et al. Bundle Fusion: (2017) por Angela Dai et al. SOFT-SLAM: (2017) por Igor Cvišić et al. KO-Fusion: (2019) por Charlie Housego et al.
Método basado en características	Disperso	<ul style="list-style-type: none"> MonoSLAM: (2007) por Andrew J Davison et al. PTAM: (2007) por Georg Klein et al. ORB-SLAM: (2011) por Ethan Rublee et al.



		<ul style="list-style-type: none"> ● ENFT-sfm: (2016) por Guofeng Zhang et al. ● proSLAM: (2018) por D. Schlegel et al. ● OpenVSLAM: (2019) por Shinya Sumikura et al. ● TagSLAM: (2019) por Bernd Pfrommer et al.
Odometría inercial visual (VIO)		<ul style="list-style-type: none"> ● MSCKF: (2007) por Anastasios I Mourikis et al. ● SSF: (2012) por Stephan M Weiss ● ROVIO: (2015) por Michael Bloesch et al. ● OKVIS: (2015) por Stefan Leutenegger et al. ● VINS: (2017) por Peiliang Li et al. ● VINS-Mobile: (2017) por Tong Qin et al. ● ICE-BA: (2018) por Haomin Liu et al. ● Maplab: (2018) por T. Schneider et al.
Aprendizaje profundo	Rasgos y detección	<ul style="list-style-type: none"> ● Pop-up SLAM: (2016) por Shichao Yang et al. ● LIFT: (2016) por Kwang Moo et al. ● DeepSLAM: (2017) por Daniel DeTone et al. ● SuperPoint: (2018) por Daniel DeTone et al. ● GCN-SLAM: (2019) por Jiexiong Tang et al. ● SalienteDSO: (2019) por Huai-Jen et al. ● CubeSLAM: (2019) por Shichao Yang et al. ● MonoGRNet: (2019) por Zengyi Qin et al.
	Reconocimiento y segmentación	<ul style="list-style-type: none"> ● SLAM++: (2013) por Renato F. et al. ● Semanticfusion: (2017) por John McCormac et al. ● MarrNet: (2017) por Jiajun Wu et al. ● DA-RNN: (2017) por Yu Xiang et al. ● 3DMV: (2018) por Angela Dai et al. ● Pix3D: (2018) por Xingyuan Sun et al. ● ScanComplete: (2018) por Angela Dai et al. ● Fusion++: (2018) por John McCormac et al. ● SegMap 3D-SIS: (2018) por Renaud Dubé et al. ● CCNet: (2018) por Zilong Huang et al. ● DenseFusion: (2019) por Chen Wang et al.
	Escala de recuperación	<ul style="list-style-type: none"> ● CNN-SLAM: (2017) por Keisuke Tateno et al. ● DeepVO: (2016) por Vikram Mohanty et al. ● UnDeepVO: (2018) por Ruihao Li et al. ● GeoNet: (2018) por Zhichao Yin et al. ● CodeSLAM: (2018) por Michael Bloesch et al. ● Mono-stixels: (2018) por Fabian Brickwedde et al. ● GANVO: (2018) por Yasin Almalioglu et al. ● DeepMVS: (2018) por Po-Han Huang et al. ● DeepV2D: (2018) por Jia Deng Zachary Teed ● GEN-SLAM: (2019) por Punarjay Chakravarty et al. ● GS3D: (2019) por Buyu Li et al.
	Salida y optimización de pose	<ul style="list-style-type: none"> ● PoseNET: (2015) por Alex Kendall et al. ● VInet: (2017) por Ronald Clark et al. ● DeepVO: (2017) por Sen Wang et al. ● SFMlearner: (2017) por Tinghui Zhou et al. ● SSFNet: (2017) por Sudheendra Vijayanarasimhan et al. ● MID-Fusion: (2017) por Martin Rünz et al. ● VidLoc: (2017) por Ronald Clark et al. ● VSO: (2018) por Konstantinos Nektario et al.
	Localización a largo plazo	<ul style="list-style-type: none"> ● X-View: (2018) por Abel Gawel et al.



	SLAM dinámico	<ul style="list-style-type: none">● RDSLAM: (2013) por Wei Tan et al.● Co-Fusion: (2017) por Martin Rünz et al.● DS-SLAM: (2018) por Chao Yu et al.● MaskFusion:(2018): M. Runzet al.● Detect-SLAM: (2018) por Fangwei Zhong et al.● DynaSLAM: (2018) por Berta Bescos et al.● StaticFusion: (2018) por Raluca Scona et al.
--	---------------	--

Tabla 23: “Evolución de soluciones con sensores visuales” [39]

11. FUENTES BILIOGRÁFICAS

- [1] Gianluca Zaffiro y Giuseppe Marone, “Smart Mobility: new roles for Telcos in the emergence of electric and autonomous vehicles”, AEIT, Fig. 1, 2019.
- [2] Vinayak V. Dixit, Sai Chand, Divya J. Nai, “Autonomous Vehicles: Disengagements, Accidents and Reaction Times”, PLUS ONE, 2016.
- [3] Alexander Eriksson y Neville A Stanton, “Take-over time in highly automated vehicles: non-critical transitions to and from manual control”, Human Factors, 2017.
- [4] Liangkai Liu, Sidi Lu, Ren Zhong, Baofu Wu, Yongtao Yao, Qingyang Zhang y Weisong Shi, “Computing Systems for Autonomous Driving: State-of-the-Art and Challenges”, IEEE Internet of Things Journal, 2020.
- [5] You Li y Javier Ibanez-Guzman, “Lidar for Autonomous Driving: The principles, challenges, and trends for automotive lidar and perception systems”, IEEE Internet of Things Journal, 2020.
- [6] Andrzej Stateczny, Marta Wlodarczyk-Sielicka y Pawel Burdziakowski, “Sensors and Sensor’s Fusion in Autonomous Vehicles”, MDPI Sensors, 2021
- [7] Thomas Winkle, “Product Development within Artificial Intelligence, Ethics and Legal Risk: Exemplary for Safe Autonomous Vehicles”, Springer, 2021
- [8] Junko Yoshida, Teardown: Tesla’s Hardware Retrofits for Model 3, 2020, [Online]. Available: <https://www.etasia.com/teslas-hardware-retrofits-for-model-3/>
- [9] Junko Yoshida, Teardown: Lessons Learned From Audi A8, 2020, [Online]. Available: <https://www.etasia.com/teardown-lessons-learned-from-audi-a8/>
- [10] Comisión Europea, “Draft implementing regulation - Ares (2022)2667391”, 2022, [Online]. Available: https://ec.europa.eu/info/law/better-regulation/have-your-say/initiatives/12152-Automated-cars-technical-specifications_en
- [11] Andrea Ceccarelli y Francesco Secci, “RGB cameras failures and their effects in autonomous driving applications”, IEEE Transactions on Dependable and Secure Computing, 2022
- [12] K. Toyama, J. Krumm, B. Brumitt y B. Meyers, “Wallflower: Principles and practice of background maintenance”, Proceedings of the Seventh IEEE International Conference on Computer Vision 1, 1999, pp. 255–261. <http://dx.doi.org/10.1109/ICCV.1999.791228>.
- [13] Marie-Neige Chapel, Thierry Bouwmans, “Moving objects detection with a moving camera: A comprehensive review”, Computer Science Review, Volumen 38, 2020
- [14] Igor Morawski, Yu-An Chen, Yu-Sheng Lin y Winston H. Hsu, “NOD: Taking a Closer Look at Detection under Extreme Low-Light Conditions with Night Object Detection Dataset”, National Taiwan University, 2021
- [15] You Li y Javier Ibanez-Guzman, “Lidar for Autonomous Driving: The principles, challenges, and trends for automotive lidar and perception systems”, Renault S.A.S, 2020
- [16] Santiago Royo y Maria Ballesta-Garcia, “An Overview of Lidar Imaging Systems for Autonomous Vehicles”, MDPI Applied Sciences, 2019
- [17] Daniel Reyes Duran, Elliot Robinson, Andrew J. Kornecki y Janusz Zalewski, “Safety Analysis of Autonomous Ground Vehicle Optical Systems: Bayesian Belief Networks Approach”, Federated Conference on Computer Science and Information Systems, 2013
- [18] Shaoshuai Shi, Chaoxu Guo, Li Jiang, Zhe Wang, Jianping Shi, Xiaogang Wang y Hongsheng Li, “PV-RCNN: Point-Voxel Feature Set Abstraction for 3D Object Detection”, arXiv:1912.13192, 2020



- [19] Shaoshuai Shi, Li Jiang, Jiajun Deng, Zhe Wang, Chaoxu Guo, Jianping Shi, Xiaogang Wang y Hongsheng L, “PV-RCNN++: Point-Voxel Feature Set Abstraction With Local Vector Representation for 3D Object Detection”, arXiv:2102.00463, 2021
- [20] Jonah Gamba, “Radar Signal Processing for Autonomous Driving”, Springer, 2020
- [21] Jungang Yang, Tian Jin, Chao Xiao, y Xiaotao Huang, “Compressed Sensing Radar Imaging: Fundamentals, Challenges, and Advances”, MDPI Sensors, 2019
- [22] Zhiqing Wei, Fengkai Zhang, Shuo Chang, Yangyang Liu, Huici Wu y Zhiyong Feng, “MmWave Radar and Vision Fusion for Object Detection in Autonomous Driving: A Review”, MDPI Sensors, 2022
- [23] Taohua Zhou, Mengmeng Yang, Kun Jiang, Henry Wong y Diange Yang, “MMW Radar-Based Technologies in Autonomous Driving: A Review”, MDPI Sensors, 2020
- [24] Sushank ChaudharyID, Lunchakorn Wuttisittikulkiy, Muhammad Saadi, Abhishek Sharma, Sattam Al Otaibi, Jamel NebhenID, Demostenes Zegarra Rodriguez, Santosh KumarID, Vishal Sharma, Gridsada Phanomchoeng y Ratchatin Chancharoen, “Coherent detection-based photonic radar for autonomous vehicles under diverse weather conditions”, PLUS ONE, 2021
- [25] Continental, “DataSheet ARS4-B”, 2022, [Online]. Available: http://continental.automotive-approvals.com/index.php?produkt=tlJBo3IAqnAPd3pctOR8h6o7-gFICqwDi4aVd6LnYuhKd-7&download=yes&type=i29jb2h6iPBscOBK9nlyfRIezMiOgcc2TMUU3_zypORziDS8EyY1rfMbJh3IH9IRxsWW&cid=i29jb2h6iPBscOBK9nlyfYQ6T2S_CNhpmu0DqT2GtR9neG8&pid=i29jb2h6iPBscOBK9nlyfQ8738q6GMVwcyDT1PK9PJSd26f&id=i29jb2h6iPBscOBK9nlyf-w8Ft_sgfleFDNdiQCIaRDQv_a
- [26] A.J. Wileman, S. Perinpanayagam, “Failure mechanisms of radar and RF systems”, 2nd International Through-life Engineering Services Conference, 2013
- [27] Stefan Muckenhuber, Eniz Museljc y Georg Stettinger, “Performance evaluation of a state-of-the-art automotive radar and corresponding modeling approaches based on a large labeled dataset”, Journal of Intelligent Transportation Systems, 2021
- [28] Nicolas Scheiner, Florian Kraus, Nils Appenrodt, Jürgen Dickmann y Bernhard Sick, “Object detection for automotive radar point clouds – a comparison”, Springer Open AI Perspectives, 2021
- [29] Wan Rahiman y Zafariq Zainal, “An Overview of Development GPS Navigation for Autonomous Car”, IEEE, 2013
- [30] Carl Milne, “Determination of the Effects of GPS Failures on Aviation Applications”, Centre for Transport Studies Department of Civil and Environmental Engineering Imperial College London, 2009
- [31] José Manuel Lozano Domínguez y Tomás Jesús Mateo Sanguino, “Review on V2X, I2X, and P2X Communications and Their Applications: A Comprehensive Analysis over Time”, MDPI Sensors, 2019
- [32] Yang Gao, Hao Jing, Mehrdad Dianati, Craig M Hancock, y Xiaolin Meng, “Performance Analysis of Robust Cooperative Positioning based on GPS/UWB Integration for Connected Autonomous Vehicles”, IEEE, 2015
- [33] Vasilis Maglogiannis, Dries Naudts, Seilendria Hadiwardoyo, Daniel van den Akker, Johann Marquez-Barja y Ingrid Moerman, “Experimental V2X Evaluation for C-V2X and ITS-G5 Technologies in a Real-Life Highway Environment”, IEEE, 2010
- [34] Unai Hernandez-Jayo y Idoia De-la-Iglesia, “Reliability Analysis of IEEE 802.11p Wireless Communication and Vehicle Safety Applications”, IEEE, 2018
- [35] Mario H. Castañeda Garcia, Alejandro Molina-Galan, Mate Boban, Javier Gozalvez, Baldomero Coll-Perales, Taylan Sahin y Apostolos Kousaridas, “A Tutorial on 5G NR V2X Communications”, IEEE, 2021
- [36] Jingyuan Tang, Han Luo, Weiwei Chen, Peter Kok-Yiu Wong y Jack C.P. Cheng, “IMU-based full-body pose estimation for construction machines using kinematics modeling”, Automation in Construction, Volumen 138, 2021
- [37] Chaulk Mitchell, “Inertial Measurement Unit (IMU) testing procedure”, NRC CNRC, Consejo nacional de investigación de Canadá, 2011
- [38] Cesar Cadena, Luca Carlone, Henry Carrillo, Yasir Latif, Davide Scaramuzza, Jose Neira, Ian Reid, y John J. Leonard, “Past, Present, and Future of Simultaneous Localization and Mapping: Toward the Robust-Perception Age” IEEE, 2016
- [39] Baichuan Huang, Jun Zhao y Jingbin Liu, “A Survey of Simultaneous Localization and Mapping”, arXiv:1909.05214, 2020



- [40] Natasha Govender, “Evaluation of Feature Detection Algorithms for Structure from Motion”, Council for Scientific and Industrial Research, South Africa, 2009
- [41] Jean-Emmanuel Deschaud, “IMLS-SLAM: scan-to-model matching based on 3D data”, arXiv:1802.08633, 2018
- [42] Onur Ozyesil, Vladislav Voroninski, Ronen Basri y Amit Singer, “A Survey of Structure from Motion”, arXiv:1701.08493v2, 2017
- [43] Liangkai Liu, Sidi Lu, Ren Zhong, Baofu Wu, Yongtao Yao, Qingyang Zhang, Weisong Shi, “Computing Systems for Autonomous Driving: State-of-the-Art and Challenges”, arXiv:2009.14349v3, 2020
- [44] Sony, “IMX490”, 2019, [Online]. Available: <https://www.sony-semicon.co.jp/products/common/pdf/IMX490.pdf>
- [45] Nerian vision technologies, “Scarlet 3D Depth Camera”, 2022, [Online], Available: <https://nerian.com/products/scarlet-3d-depth-camera/>
- [46] Velodyne Lidar, “Ultra Pluck”, 2019, [Online], Available: https://velodynelidar.com/wp-content/uploads/2019/12/63-9378_Rev-F_Ultra-Puck_Datasheet_Web.pdf
- [47] ART, “ART Midrange Product Brief”, 2013, [Online], Available: [https://www.radartutorial.eu/19.kartei/05.perimeter/pubs/ART%20Midrange%20Product%20Brief_A4_v2.0%20\(June%202013\).pdf](https://www.radartutorial.eu/19.kartei/05.perimeter/pubs/ART%20Midrange%20Product%20Brief_A4_v2.0%20(June%202013).pdf)
- [48] Baumgartner, Daniel, et al. "Benchmarks of low-level vision algorithms for DSP, FPGA, and mobile PC processors." Embedded Computer Vision. Springer, Pág. 101-120, 2009.
- [49] Xu Lei, Bin Feng, Guiping Wang, Weiyu Liu et al., “A Novel FastSLAM Framework Based on 2D Lidar for Autonomous Mobile Robot”, MDPI electronics, 2020
- [50] J. Felipe Arango, Luis M. Bergasa, Pedro A. Revenga, Rafael Barea, Elena López-Guillén, Carlos Gómez-Huélamo, Javier Araluce and Rodrigo Gutiérrez “Drive-By-Wire Development Process Based on ROS for an Autonomous Electric Vehicle”, MDPI sensors, 2020
- [51] AMD Ryzen Threadripper 3970X, [Online]. Available: <https://www.pccomponentes.com/amd-ryzen-threadripper-3970x>
- [52] Gigabyte GeForce RTX 3090 Gaming OC 24G 24GB GDDR6X, [Online]. Available: <https://www.pccomponentes.com/gigabyte-geforce-rtx-3090-gaming-oc-24g-24gb-gddr6x>
- [53] Kingston FURY Beast DDR5 4800MHz 16GB CL38, [Online]. Available: <https://www.pccomponentes.com/kingston-fury-beast-ddr5-4800mhz-16gb-cl38>
- [54] Gigabyte B560M DS3H V2, [Online]. Available: <https://www.pccomponentes.com/gigabyte-b560m-ds3h-v2>
- [55] BitFenix Fórmula Gold Fuente de Alimentación 650W 80+ Gold, [Online]. Available: <https://www.pccomponentes.com/bitfenix-formula-gold-fuente-de-alimentacion-650w-80-gold>
- [56] IMX179 8MP USB Camera, [Online]. Available: <https://www.waveshare.com/imx179-8mp-usb-camera-a.htm>
- [57] Sony IMX490 CMOS Image Sensor, [Online]. Available: <https://www.photoxels.com/sony-imx490-cmos-image-sensor-for-automotive-cameras-with-5-4-mp-the-industrys-highest-in-a-sensor-that-delivers-simultaneous-hdr-shooting-and-led-flicker-mitigation-get-high-precision-reco/>
- [58] Velodyne LiDAR introduces 32-channel ULTRA Puck VLP-32A high definition real-time 3D LiDAR, [Online]. Available: <https://www.greencarcongress.com/2016/04/velodyne-lidar-introduces-32-channel-ultra-puck-vlp-32a-high-definition-real-time-3d-lidar-.html>
- [59] CABLE UTP CAT.6 FLEXIBLE PRECIO 1 METRO, [Online]. Available: <https://www.electrowifi.es/cables-de-red/cable-utp-cat6-flexible-cca>
- [60] Suministro y montaje acero, [Online]. Available: [https://bdc.f-ive.es/BDC19/1/EEHE.1\\$/aabcba](https://bdc.f-ive.es/BDC19/1/EEHE.1$/aabcba)
- [61] SafeLightPro, [Online]. Available: <https://www.amazon.es/dp/B009GFML20?tag=mundoher-21&linkCode=osi&th=1&psc=1>
- [62] Detector movimiento interior, [Online]. Available: [https://bdc.f-ive.es/BDC19/1/EIDD.2\\$/baa](https://bdc.f-ive.es/BDC19/1/EIDD.2$/baa)