



**UNIVERSIDAD POLITÉCNICA SALESIANA  
SEDE GUAYAQUIL  
CARRERA DE INGENIERÍA DE COMPUTACIÓN**

**ANÁLISIS COMPARATIVO DE ALGORITMOS DE DETECCIÓN DE OBJETOS  
CON SENSOR LÁSER LIDAR 3D**

Trabajo de titulación previo a la obtención del  
Título de Ingeniero en Ciencia de la Computación

AUTOR: ANDREA VALENTINA CARDENAS GARCIA, ANGEL EDUARDO

CEVALLOS VILLACIS

TUTOR: MIGUEL ANGEL QUIROZ MARTINEZ

Guayaquil – Ecuador

2022

**CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE  
TITULACIÓN**

Yo, Andrea Valentina Cardenas Garcia, Angel Eduardo Cevallos Villacis con documento de identificación N° 0932118920, 0954188397 manifiesto que:

Soy el autor y responsable del presente trabajo; y, autorizo a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Guayaquil, 03 de marzo del año 2022

Atentamente,



---

Andrea Valentina Cárdenas García  
N° 0932118920



---

Angel Eduardo Cevallos Villacis  
N° 0954188397

**CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE  
TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA**

Nosotros, Andrea Valentina Cárdenas García, Angel Eduardo Cevallos Villacis con documento de identificación No. 0932118920, 0954188397 expreso mi voluntad y por medio del presente documento cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor(a) del Artículo Académico: “Nombre del artículo sin punto final”, el cual ha sido desarrollado para optar por el título de: Ingeniero de Sistemas, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribo este documento en el momento que hago la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Guayaquil, 03 de marzo del año 2022

Atentamente,



---

Andrea Valentina Cárdenas García  
0932118920



---

Angel Eduardo Cevallos Villacis  
0954188397

## CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, **Miguel Ángel Quiroz Martínez** con documento de identificación N° **0922799655**, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: ANÁLISIS COMPARATIVO DE ALGORITMOS DE DETECCIÓN DE OBJETOS CON SENSOR LÁSER LIDAR 3D, realizado por Andrea Valentina Cárdenas García, Angel Eduardo Cevallos Villacis con documento de identificación N° 0932118920, 0954188397 obteniendo como resultado final el trabajo de titulación bajo la opción Artículo Académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Guayaquil, 03 de marzo del año 2022

Atentamente,



---

Miguel Ángel Quiroz Martínez

0922799655

## DEDICATORIA

Dedico este trabajo a Dios, por habernos permitido lograr este gran objetivo, como es terminar nuestra carrera universitaria y especialmente a nuestros padres por el apoyo incondicional que nos han brindado para llegar a esta instancia de nuestros estudios.

A nuestros hermanos y hermanas que estuvieron con nosotros en los momentos en que ya no podíamos continuar con este gran reto, pero nos brindaron con sus palabras de ánimos a seguir luchando por nuestros sueños.

A nuestro tutor, el Msc. Miguel Quiroz, por brindarnos su confianza para realizar este artículo y no rendirse con nosotros en este largo camino hacia la titulación.

A nuestros mejores amigos de la universidad Steven, Mario, Eduardo, Andrea, Nathaly, Cristobal, Bryan y Jennifer quienes siempre nos brindaron su apoyo y palabras de aliento en el transcurso de toda nuestra carrera a pesar de los obstáculos que se presentaron.

## **AGRADECIMIENTO**

Agradezco de manera especial a nuestros padres Fanny, Edison, Dolores y Luis quienes han sido un apoyo moral e incondicional y económico para lograr este fin. Gracias por su paciencia y amor.

A nuestro tutor Miguel Quiroz una de las personas que más admiramos por su inteligencia, conocimientos y entrega a su labor como docente, a quien le debemos el hecho de que este artículo tenga los menores errores posibles.

A nuestros hermanos y hermanas por apoyarnos sin condiciones, a nuestros amigos por su motivación de seguir adelante a pesar de los tropiezos del camino.

## RESUMEN

La tecnología LiDAR cada vez está teniendo un avance progresivo constante en el campo automotriz en especial a lo referente como son los automóviles autónomos, siendo la industria automotriz la que ha estado incorporando esta clase de sensores láser LiDAR (Light Detector and Ranging) para aplicaciones de reconocimiento de objetos (carretera) gracia a los beneficios que contribuye. El presente trabajo se enfoca en identificar el mejor algoritmo de detección de objetos en carretera mediante modelos comparativos para un efectivo reconocimiento de los elementos en la cámara láser LiDAR 3D, a través de un análisis de los algoritmos de reconocimientos de carretera utilizando las revistas científicas y repositorio KITTI para la selección del mejor algoritmo, enfocados especialmente en los algoritmos PLDAR y SNE-RoadSeg para la detección rendimiento en cuestión de precisión y media máxima como métricas comparativas.

**Palabras claves:** LiDAR, PLDAR, SNE-RoadSeg, KITTI.

## ABSTRACT

LiDAR technology is having a constant progressive advancement in the automotive field, especially in autonomous cars, being the automotive industry the one that has been incorporating this kind of LiDAR (Light Detector and Ranging) laser sensors for object recognition applications (road) thanks to the benefits it contributes. The present work focuses on identifying the best road object detection algorithm through comparative models for an effective recognition of the elements in the 3D LiDAR laser camera, through an analysis of road recognition algorithms using scientific journals and KITTI repository for the selection of the best algorithm, focusing especially on the PLDAR and SNE-RoadSeg algorithms for detection performance in terms of accuracy and maximum mean as comparative metrics.

**Key words:** LiDAR, PLDAR, SNE-RoadSeg, KITTI.

**ÍNDICE DE CONTENIDO**

1. INTRODUCCIÓN.....	10
2. REVISIÓN DE LITERATURA .....	11
3. METODOLOGÍA.....	13
3.1. Métodos y técnicas de Recopilación de datos empleadas.....	13
3.2. Métodos y técnicas de Análisis de datos.....	13
4. RESULTADOS .....	16
5. CONCLUSIÓN .....	17
REFERENCIAS.....	18

## 1. INTRODUCCIÓN

La tecnología LiDAR cada vez está teniendo un avance progresivo constante en el campo automotriz en especial a lo referente como son los automóviles autónomos. Desarrolladores, fabricantes e investigadores de la industria automotriz han estado incorporando a esta clase de sensores láser LiDAR (Light Detector and Ranging) (Maksymova et al., 2018) para aplicaciones de reconocimiento de objetos (carretera) gracias a los beneficios que contribuye.

Para el uso de conducción autónoma se usan algoritmos basados en CNN (Kim, 2014), DCNN (Rawat & Wang, 2017), FCN (Long et al., 2015), entre otros. En la actualidad muchos de estos algoritmos de detección de objetos en la carretera están basados en CNN (Kim, 2014) con la aplicación de la fusión de datos que ha mejorado de forma significativa a nivel de la segmentación en la escena de una imagen RGB en donde se procede a la extracción y fusión de las características.

Por otro lado, DCNN (Rawat & Wang, 2017) sus resultados con imágenes pueden tener un rendimiento bajo debido al ruido visual y la iluminación que varía en cada imagen, e incluso imágenes borrosas por lo que se debe combinar para una mayor precisión con información LiDAR para una mejora en la detección de carreteras (Chen et al., 2019).

Sin embargo, FCN (Long et al., 2015) ha logrado resultados prometedores en la detección de carreteras en los puntos de referencia de la segmentación semántica y actuando extractor de características de alta resolución permitiendo una precisión en la segmentación (Caltagirone et al., 2017).

Por ello nuestro objetivo es identificar el mejor algoritmo de detección de objetos en carretera mediante modelos comparativos para un efectivo reconocimiento de los elementos en la cámara láser LiDAR 3D, a través de un análisis de los algoritmos de reconocimientos de carretera utilizando las revistas científicas y repositorio KITTI (Fritsch et al., 2013) para la selección del mejor algoritmo.

## 2. REVISIÓN DE LITERATURA

Los sensores automotrices LiDAR (Light Detection and Ranging) se van a convertir en un factor clave en los carros autónomos, debido a que podrían dar información preciada en condiciones a las que otros sensores de observación circundantes no son propensos (Maksymova et al., 2018). Conforme con la configuración del sensor, los sistemas LiDAR producen millones de puntos de datos por segundo, lo cual equivale a varios GBit/seg de datos sin procesar que tienen que transferirse a una ECU para una computación en nube de puntos de vista 3D en tiempo real (Golla & Klein, 2015). A lo largo de cada investigación, un sensor LiDAR recopila una nube de aspectos con las coordenadas x, y y z de los objetos circundantes (Wu, 2018).

En la actualidad a pesar de los avances tecnológicos aún se ve comprometido el trabajo de la detección de carreteras a través de imágenes visuales, debido a diversos factores como los cambios de iluminación e inclusive las imágenes borrosas (Shinzato et al., 2014). Para una mayor fiabilidad en la detección de carreteras se puede incorporar los datos del sensor LiDAR porque son menos susceptibles al ruido que pueden poseer dichas imágenes (Caltagirone et al., 2017). Sin embargo, es un reto el poder incorporar los datos LiDAR y sus características extraídas ya que no comparten el mismo campo con los datos y características visuales, por lo que puede restringir los beneficios de la información que nos da LiDAR con sus datos para la detección de carreteras. Para afrontar este reto se presenta un enfoque para la detección de carreteras en imágenes como lo es PLIDAR conocida como la adaptación progresiva LiDAR que ayuda a mejorar el rendimiento de la detección de imágenes ya que nos permite adaptar la información LiDAR para la detección de carreteras (Chen et al., 2019).

La detección de espacio libre es algo esencial para vehículos que se auto conducen (Sless et al., 2019). La detección de espacio de manera general clasifica cada píxel en una imagen RGB, una vez clasificados los píxeles se los utiliza en varios modules en el sistema autónomo de los vehículos para predicción de trayectoria (Cai et al., 2020) de los vehículos para que manejen seguro (Fan, Wang, et al., 2020).

Hay dos maneras de categorizar la detección de espacios libres existentes en la carretera y estos son tradicionales o basados en aprendizaje (Fan, Ozgunalp, et al., 2020). Los tradicionales donde la segmentación de carretera se ajusta usando un model B-spline (Wedel et al., 2009).

U-net (Ronneberger et al., 2015) ha demostrado efectividad sobre el uso de conexión de saltos para lograr recuperar una resolución completa espacial, pero aun así aquellos saltos impulsan las agregaciones solo en los mapas de características del algoritmo en la misma escala del codificador y el decodificador creando una restricción redundante (Fan, Wang, et al., 2020).

En RoadSeg se utiliza dos tipos de codificadores, uno que utiliza la gama de colores RGB y unos normal para la segmentación de los datos de la escena. El propósito es obtener los mapas de características de diferentes superficies, usando la combinación de ambos mapas se puede obtener un resultado más preciso. El proceso de fusionar y separar se intercala de manera secuencial para obtener más precisión y resolución en los mapas de características (Fan, Wang, et al., 2020).

RestNet (K. He et al., 2016) es la columna vertebral de estos codificadores normales, de superficie y RGB ya que básicamente sus estructuras son similares las cuales consta de varias capas entre ellas capa convolucional, capa de normalización de lotes y capa de activación de ReLU (J. He et al., 2018).

*Tabla 1. Fuente de Búsqueda de Algoritmos con su respectivo conjunto de datos a utilizar.*

<b>Algoritmos</b>	<b>Referencias</b>	<b>Conjunto de Datos</b>
<b>PLARD</b>	(Chen et al., 2019)	Dataset KITTI Road/Lane Detecction, base kit with: left color images, calibration and training labels (Fritsch et al., 2013), ADI, plard_kitti_road.pth
<b>SNE-RoadSeg</b>	(Fan, Wang, et al., 2020)	Dataset KITTI Road/Lane Detecction, base kit with: left color images, calibration and training labels (Fritsch et al., 2013), kitti_net_RoadSeg.pth, checkpoints, depth_u16.

### 3. METODOLOGÍA

#### 3.1. Métodos y técnicas de Recopilación de datos empleadas

Para esta investigación, se aplicó el método deductivo para determinar el algoritmo con mayor eficiencia y precisión en la detección de objetos (carretera), por efectos del mismo se exploraron las estructuras de modelos como SNE-RoadSeg (Fan, Wang, et al., 2020) y PLDAR (Chen et al., 2019) realizando el respectivo Test en cada uno de los algoritmos mencionados, utilizando el dataset de KITTI (Fritsch et al., 2013) que proporciona imágenes RGB que nos ayudaran en el testeo respectivo.

Cada uno de los dos algoritmos tratados en este artículo tiene su apoyo en una distinta metodología, por lo que sus resultados varían al realizar el respectivo test por eso determinamos una estructura base con los puntos significativos y similares en ambos algoritmos tal como lo detalla la siguiente (Figura 1).

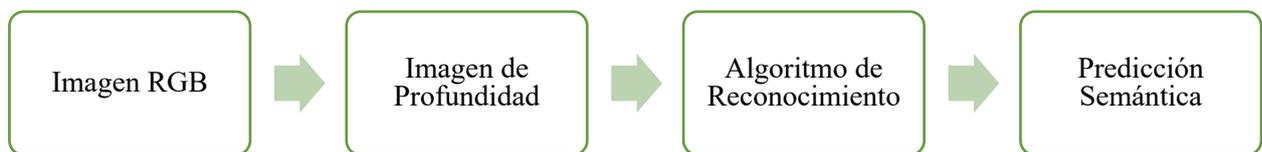


Figura 1. Estructura básica de un modelo de reconocimiento.

#### 3.2. Métodos y técnicas de Análisis de datos

El análisis de datos se desarrolló en función de los objetivos específicos e interrogante, respondiendo a la pregunta ¿Cómo puedo seleccionar un algoritmo de reconocimiento de objeto utilizando una cámara LIDAR 3D Velodyne?

Para esto analizamos los algoritmos de reconocimiento para profundizar en el esquema que presenta cada uno mediante el uso de redes neuronales tales como CNN (Kim, 2014), DCNN (Rawat & Wang, 2017), FCN (Long et al., 2015), entre otros. El uso de librerías tales como Numpy, Pytorch, OpenCv, entre otros fue fundamental para la interpretación de imágenes RGB proporcionadas por el repositorio KITTI (Fritsch et al., 2013) y otras herramientas que se detallan en el presente trabajo.

Pytorch es una librería optimizada de tensor para el aprendizaje profundo usando GPU Y CPU este fue utilizado junto con CUDA (*CUDA Zone | NVIDIA Developer*, n.d.). Para hacer el respectivo test de las imágenes en los algoritmos SNE-RoadSeg (Fan, Wang, et al., 2020) y PLDAR (Chen et al., 2019) se usó estas dos librerías ya que contiene estructuras con las cuales se pueden analizar tensores multi dimensionales utilizando los recursos de la tarjeta gráfica NVIDIA GeForce GTX 1650.

CUDA (*CUDA Zone | NVIDIA Developer*, n.d.) es una plataforma de computación paralela y de modelo de programación él fue desarrollado por NVIDIA el cual permite acelerar drásticamente la velocidad de aplicaciones con el poder de las GPU's. Además, nos facilita un conjunto de herramientas denominado CUDA Toolkit (*CUDA Toolkit | NVIDIA Developer*, n.d.) el cual provee un ambiente de desarrollo para crear aplicación de alto rendimiento basadas en aceleración por GPU, este conjunto de herramientas incluye librerías de aceleración de GPU, optimización; las cuales junto a la librería Pytorch permitió realizar los análisis mencionados anteriormente.

OpenCV (Marin, 2020) es una librería que permite la identificación de objetos en imágenes, de esta manera ayuda en el reconocimiento de carretera con ayuda de CUDA para una optimización más eficiente en el algoritmo a su vez permite ajustar el tamaño de las imágenes para identificar las carreteras en las imágenes del dataset KITTI (Fritsch et al., 2013).

A continuación, se detalla los pasos que se siguieron para determinar el mejor algoritmo de detección de objeto (carretera):

#### Algoritmo SNE-RoadSeg

1. Se importaron las librerías (numpy, open cv, pytorch).
2. Se descargo e instalo CUDA ToolKit (*CUDA Toolkit | NVIDIA Developer*, n.d.) de la página oficial de NVIDIA.
3. Se descargo e importo el dataset KITTI Road/Lane (Fritsch et al., 2013) que contiene las imágenes RGB para el testeo respectivo.
4. Se descargo e implementa el depth\_u16 en función de los datos LiDAR proporcionados en el conjunto de datos de carreteras de KITTI (Fritsch et al., 2013) teniendo en cuenta que depth\_u16 posee el formato de datos uint16, y la profundidad real en metros.

5. Se descargo la carpeta checkpoints que contiene el kiiti\_net\_RoadSeg.pth el cual es el modelo pre entrenado de este algoritmo
6. Al ejecutar el testeo se pasa como argumento la ruta donde se encuentra el modelo entrenado kiiti\_net\_RoadSeg.pth.
7. Utilización de las librerías numpy , pytorch-cuda, opencv para realizar las predicciones respectiva de las carreteras en las imágenes proporcionadas por el dataset KITTI (Fritsch et al., 2013).
8. Al terminar de ejecutar el testeo nos dirigimos a la carpeta testresults donde se encuentra las imágenes con la carretera detectada.

#### Algoritmo PLARD

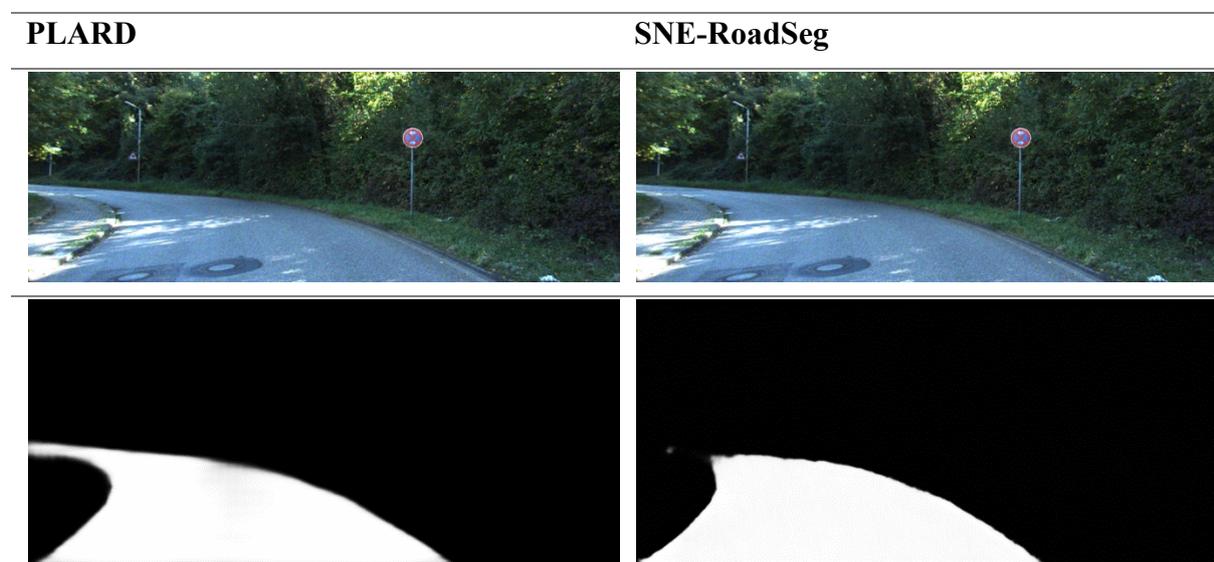
1. Se importaron las librerías (numpy, open cv, pytorch).
2. Se descargo e instalo CUDA ToolKit (NVIDIA CORPORATION, CUDA Toolkit, 2022) de la página oficial de NVIDIA.
3. Se descargo e importo el dataset KITTI Road/Lane (Fritsch et al., 2013) que contiene las imágenes RGB para el testeo respectivo.
4. Se descarga e implementa la carpeta "ADI" que contiene las imágenes de diferencia de altitud.
5. Al ejecutar el testeo se pasa como argumento la ruta donde se encuentra el modelo entrenado plard\_kitti\_road.pth y la ruta del dataset KITTI Road/Lane (Fritsch et al., 2013) que vamos a testear.
6. Utilización de las librerías numpy , pytorch-cuda, open cv para realizar las predicciones respectiva de las carreteras en las imágenes proporcionadas por el dataset KITTI (Fritsch et al., 2013).
7. Al terminar de ejecutar el testeo nos dirigimos a la carpeta outputs/results donde se encuentra las imágenes con la carretera detectada.

#### 4. RESULTADOS

Al realizarse el análisis de los algoritmos SNE-RoadSeg (Fan, Wang, et al., 2020) y PLDAR (Chen et al., 2019), utilizando un procesador de 3.70 GHz y una tarjeta gráfica NVIDIA Geforce GTX 1650 bajo un sistema operativo Windows 10, el test se realizó con el dataset proporcionado por el repositorio KITTI (Fritsch et al., 2013).

Mediante la implementación de estos algoritmos con sus respectivos modelos en función del tiempo de testeo se pudo comprobar la precisión y efectividad PLDAR (Chen et al., 2019) de en comparativa con SNE-RoadSeg (Fan, Wang, et al., 2020) como se muestra en la Tabla 2. En donde se puede apreciar el reconocimiento de objetos en este caso la carretera dicha precisión al trazar toda la carretera incluyendo la curva con la que finaliza a partir de la imagen RGB que nos proporciona el dataset KITTI (Fritsch et al., 2013).

Tabla 2. Comparativa entre algoritmos de reconocimiento (PLDAR/SNE-RoadSeg)



De esta forma se analizó la detección de la carretera comprobando que el algoritmo PLDAR (Chen et al., 2019) logra una mayor precisión al momento de delimitar los bordes de la carretera a pesar de los objetos externos. También mostraba un uso menor en memoria al realizar el testeo como se muestra en la Tabla 3.

Tabla 3. Tiempo y Peso de testeo Algoritmos con los resultados

Algoritmo	Peso (aproximado)	Tiempo de Testeo (minutos)
PLARD	3GB	22
SNE-RoadSeg	6GB	40

## 5. CONCLUSIÓN

Con el fin de identificar el mejor algoritmo de detección de objetos en carretera mediante modelos comparativos para un efectivo reconocimiento de los elementos en la cámara láser LiDAR 3D, se procedió con el análisis de los algoritmos SNE-RoadSeg y PLDAR al recolectar la información de revistas científicas y repositorio KITTI encontrándose que ambas manejan una estructura base para procesamiento de las imagen RGB proporcionados por el dataset KITTI ROAD LANE que finaliza con la predicción semántica.

Se considero en el presente trabajo las siguientes métricas, tales como, Precisión (PRE), Media Máxima (MMax) y la Recuperación (REC) para el análisis comparativo de los algoritmos, concluyendo que PLDAR alcanza una PRE de 97.19%, MMax 97.03% y REC 96.88% que supera en comparación de SNE-RoadSeg con una PRE de 96.90%, MMax 96.75% y REC 96.61%, determinado que el algoritmo PLDAR ha demostrado su eficacia en la detección de objetos en este caso la carretera logrando un excelente rendimiento en cuestión de precisión y media máxima.

## REFERENCIAS

- Cai, P., Wang, S., Sun, Y., & Liu, M. (2020). Probabilistic End-to-End Vehicle Navigation in Complex Dynamic Environments with Multimodal Sensor Fusion. *IEEE Robotics and Automation Letters*, 5(3), 4218–4224. <https://doi.org/10.1109/LRA.2020.2994027>
- Caltagirone, L., Scheidegger, S., Svensson, L., & Wahde, M. (2017). Fast LIDAR-based road detection using fully convolutional neural networks. *IEEE Intelligent Vehicles Symposium, Proceedings*, 1019–1024. <https://doi.org/10.1109/IVS.2017.7995848>
- Chen, Z., Zhang, J., & Tao, D. (2019). Progressive LiDAR adaptation for road detection. *IEEE/CAA Journal of Automatica Sinica*, 6(3), 693–702. <https://doi.org/10.1109/JAS.2019.1911459>
- CUDA Toolkit | NVIDIA Developer*. (n.d.). Retrieved March 4, 2022, from <https://developer.nvidia.com/cuda-toolkit>
- CUDA Zone | NVIDIA Developer*. (n.d.). Retrieved March 4, 2022, from <https://developer.nvidia.com/cuda-zone>
- Fan, R., Ozgunalp, U., Hosking, B., Liu, M., & Pitas, I. (2020). Pothole Detection Based on Disparity Transformation and Road Surface Modeling. *IEEE Transactions on Image Processing*, 29, 897–908. <https://doi.org/10.1109/TIP.2019.2933750>
- Fan, R., Wang, H., Cai, P., & Liu, M. (2020). SNE-RoadSeg: Incorporating Surface Normal Information into Semantic Segmentation for Accurate Freespace Detection. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12375 LNCS, 340–356. [https://doi.org/10.1007/978-3-030-58577-8\\_21](https://doi.org/10.1007/978-3-030-58577-8_21)
- Fritsch, J., Kuhn, T., & Geiger, A. (2013). A new performance measure and evaluation benchmark for road detection algorithms. *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, 1693–1700. <https://doi.org/10.1109/ITSC.2013.6728473>
- Golla, T., & Klein, R. (2015). Real-time point cloud compression. *IEEE International Conference on Intelligent Robots and Systems, 2015-December*, 5087–5092. <https://doi.org/10.1109/IROS.2015.7354093>
- He, J., Li, L., Xu, J., & Zheng, C. (2018). ReLU Deep Neural Networks and Linear Finite Elements. *Journal of Computational Mathematics*, 38(3), 502–527. <https://doi.org/10.4208/jcm.1901-m2018-0160>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-December*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Kim, Y. (2014). Convolutional Neural Networks for Sentence Classification. *EMNLP 2014 - 2014 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference*, 1746–1751. <https://doi.org/10.3115/V1/D14-1181>
- Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 07-12-June-2015*, 3431–3440. <https://doi.org/10.1109/CVPR.2015.7298965>
- Maksymova, I., Steger, C., & Druml, N. (2018). Review of LiDAR Sensor Data Acquisition and Compression for Automotive Applications. *Proceedings 2018, Vol. 2, Page 852*, 2(13), 852. <https://doi.org/10.3390/PROCEEDINGS2130852>
- Marin, R. (2020). *OpenCV, Instalación en Python y ejemplos básicos*. <https://revistadigital.inesem.es/informatica-y-tics/opencv/>

- Rawat, W., & Wang, Z. (2017). Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. *Neural Computation*, 29(9), 2352–2449. [https://doi.org/10.1162/NECO\\_A\\_00990](https://doi.org/10.1162/NECO_A_00990)
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9351, 234–241. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
- Shinzato, P. Y., Wolf, D. F., & Stiller, C. (2014). Road terrain detection: Avoiding common obstacle detection assumptions using sensor fusion. *IEEE Intelligent Vehicles Symposium, Proceedings*, 687–692. <https://doi.org/10.1109/IVS.2014.6856454>
- Sless, L., Shlomo, B. El, Cohen, G., & Oron, S. (2019). Road scene understanding by occupancy grid learning from sparse radar clusters using semantic segmentation. *Proceedings - 2019 International Conference on Computer Vision Workshop, ICCVW 2019*, 867–875. <https://doi.org/10.1109/ICCVW.2019.00115>
- Wedel, A., Badino, H., Rabe, C., Loose, H., Franke, U., & Cremers, D. (2009). B-spline modeling of road surfaces with an application to free-space estimation. *IEEE Transactions on Intelligent Transportation Systems*, 10(4), 572–583. <https://doi.org/10.1109/TITS.2009.2027223>
- Wu, J. (2018). An Automatic Procedure for Vehicle Tracking with a Roadside LiDAR Sensor Background Filtering and Lane Identification Background Filtering. *Institute of Transportation Engineers. ITE Journal*, 88, 32–37. [www.ite.org](http://www.ite.org)