

Detección de Carriles en Vías no Señalizadas mediante LIDAR y Deep Learning para Mejorar la Seguridad Vial

Vázquez Raimundo¹, Torres Carlos¹, Marighetti Jorge¹, Gramajo Sergio¹, Robledo Sanchez Alberto¹

Universidad Tecnológica Nacional, UTN, Argentina
French 414, Resistencia , Chaco

<http://www.frre.utn.edu.ar>

Equipo de trabajo G.U.D.A, Anexo, U.T.N FRRe¹
ray_vazquez_2005@ca.frre.utn.edu.ar

Abstract. Las causas principales de los accidentes de tráfico se pueden atribuir principalmente a errores humanos como la falta de atención, mal comportamiento o distracción. Para abordar este problema, muchas empresas han desarrollado técnicas para mejorar la seguridad en la conducción y reducir los siniestros viales. Este trabajo presenta un procedimiento para detectar carriles en vías no señalizadas utilizando un sensor LIDAR montado en la parte superior de un vehículo. El escáner láser captura imágenes del entorno del conductor, que luego se procesan para identificar tres regiones dentro de la distancia de frenado del vehículo: izquierda, central y derecha de la calle. Los datos recopilados se utilizan para crear conjuntos de entrenamiento y test, que se analizan mediante bibliotecas de Deep Learning para extraer patrones y construir un modelo de detección de carriles. La efectividad de este modelo se evalúa utilizando la curva ROC. Esta propuesta ofrece una solución integral para estimar la ubicación del carril del vehículo, integrando tecnología LIDAR y técnicas de Deep Learning.

Keywords: detector de carril; asistencia al conductor; seguridad vial.

1 INTRODUCCIÓN

La conducción de vehículos es una tarea altamente especializada que demanda un profundo conocimiento del tipo de vía y del entorno en el que se desenvuelve. Este conocimiento capacita a los conductores para circular con seguridad incluso en áreas de tráfico intenso. Aunque para un conductor humano experimentado pueda parecer una tarea trivial, comprender las intenciones de otros conductores sigue siendo un desafío investigativo crucial para los Sistemas Avanzados de Asistencia al Conductor (ADAS, por sus siglas en inglés). Los sistemas ADAS proporcionan apoyo al conductor mediante la implementación de sensores auxiliares en el vehículo, los cuales asisten al conductor en situaciones específicas

de manejo. Estos sistemas a menudo tienen un enfoque centrado en la seguridad, ya que la mayoría de los accidentes son causados por errores humanos. Por lo tanto, resulta aún más importante desarrollar modelos y mecanismos que puedan detectar y distinguir el comportamiento de todos los vehículos involucrados en situaciones de tráfico complejas, especialmente cuando se trata de vehículos autónomos que interactúan con aquellos conducidos por personas.

Las intersecciones presentan desafíos particulares debido a la coordinación necesaria entre los vehículos. Por lo tanto, es fundamental que cada vehículo cuente con modelos que faciliten el desarrollo de estrategias de planificación de movimiento para la toma de decisiones adecuadas. La coordinación del tráfico para mejorar la seguridad puede lograrse mediante estrategias basadas en la comunicación vehículo a vehículo o vehículo a infraestructura [1]. Sin embargo, las técnicas y estrategias desarrolladas en estos trabajos no abordan las situaciones que pueden surgir en un escenario vehicular que carece de esta tecnología de conexión. Por ejemplo, en [2] se presentan estrategias para la detección y predicción de trayectorias de vehículos en intersecciones, destacando la importancia de prever las acciones futuras de los conductores antes de ingresar o detenerse en una intersección, lo cual es fundamental para los sistemas ADAS.

Para calcular la intención de un conductor que circula en tráfico complejo, se utilizan tres enfoques diferentes. En primer lugar, se desarrolla un modelo de interacción integrado con el entorno, el cual interpreta señales y objetos presentes, como se señala en [3]. En segundo lugar, se analiza la predicción de la intención de maniobra de los automovilistas mediante la sincronización de información proveniente de un GPS, la codificación de ruedas [4][5], datos inerciales de sensores ubicados en el automóvil y sistemas de visión artificial [6][7]. En tercer lugar, se recopilan datos relevantes dentro de la cabina del automóvil, como la posición de las manos en el volante, la ubicación de los pies en los pedales, la posición de los ojos, el movimiento de la cabeza del conductor y la activación de las señales de giro [8]. Este trabajo presenta un procedimiento para detectar carriles en vías no señalizadas utilizando un sensor LIDAR montado en la parte superior de un vehículo.

2 TRABAJOS RELACIONADOS

Casi todos los sistemas actuales de asistencia al conductor usan técnicas basadas en la visión artificial para aumentar la percepción visual humana. Dichos desarrollos todavía no son robustos y presentan baja precisión. Una forma eficiente de construir modelos de detección de intención avanzados, robustos y precisos es desarrollando sistemas de fusión de sensores multimodales. Por ejemplo, investigaciones recientes han demostrado que la combinación de datos de visión por computadora y sensores internos del vehículo puede mejorar significativamente la precisión y robustez en el análisis del comportamiento del conductor y la estimación de la velocidad [9].

Actualmente, como solución a este problema, se utiliza un método de aprendizaje denominado Deep Learning. Consiste en un conjunto extenso de algoritmos encargados de extraer patrones representativos en un conjunto de datos. Dicha herramienta ha demostrado grandes ventajas en tareas de visión artificial y fusión de datos.

El rendimiento en el reconocimiento de objetos aumenta drásticamente en comparación con los enfoques convencionales antes mencionados. Es reportado que al usar el modelo Deep Learning, la detección de intención acción aumenta la precisión de 80% al 90% en comparación con los métodos tradicionales de procesamiento de imágenes [10]. El trabajo [11] muestra un sistema de detección de carril basado en redes neuronales convolucionales o CNN y red neuronal recurrente RNN. En [12] se propone un modelo de fusión de datos encargados de medir: características cinemáticas, visión artificial, interpretación de gestos del conductor utilizando algoritmos de Deep Learning. Los procesos de seguimiento de automóviles y cambio de carril generalmente se estudian en forma separada, ignorando las dependencias de estos dos comportamientos. En [13] se propone definir una trayectoria integrada de dos dimensiones basada en el modelo de aprendizaje profundo para predecir comportamientos combinados de intenciones. A su vez, en [14] se muestra un método para predecir trayectorias de vehículos en escenarios vehiculares complejos utilizando redes neuronales convolucionales. El procedimiento que aquí presentamos permite establecer posiciones de vehículos, historiales de movimiento, configuración de carreteras y las interacciones se incluyen fácilmente en el modelo de predicción utilizando representaciones visuales básicas.

3 DEFINICIÓN DEL PROBLEMA

En los últimos años, se ha prestado considerable atención al comportamiento de los conductores en entornos estructurados, es decir, situaciones donde los carriles o los semáforos están claramente definidos [15][16]. Sin embargo, hay una falta de enfoques similares para escenarios de carreteras no señalizadas, donde comúnmente no existe una infraestructura vial que imponga un ordenamiento estricto de los vehículos. En este contexto, este trabajo se centra en desarrollar un procedimiento para detectar carriles en vías no señalizadas utilizando un sensor LIDAR.

Para este propósito, se emplea un escáner láser, específicamente el S3000 de la empresa SICK. Este dispositivo captura imágenes del entorno del conductor, las cuales se procesan para identificar tres regiones dentro de la distancia de frenado del vehículo: izquierda, central y derecha de la calle. Los datos recopilados se utilizan para crear conjuntos de entrenamiento y prueba, los cuales son analizados mediante bibliotecas de Deep Learning para extraer patrones y construir un modelo de detección de carriles. Este enfoque busca abordar la carencia de soluciones para la detección de carriles en entornos no señalizados, lo cual es

fundamental para mejorar la seguridad y la eficiencia en la conducción en estos contextos.

4 MATERIALES Y MÉTODO

Para llevar a cabo el procedimiento propuesto en este trabajo, se emplea un hardware genérico adaptado para tareas de inteligencia artificial, conocido como Jetson Nano, como se detalla en [17]. La arquitectura interna de este dispositivo permite la implementación de librerías de visión artificial integradas con el lenguaje de alto nivel Python, así como frameworks de aprendizaje profundo como Darknet, TensorFlow y PyTorch. El proceso de instalación y configuración del Jetson Nano se realiza utilizando el sistema ROS (Sistema Operativo Robótico) para facilitar la captura de datos del S3000 y la creación de archivos bag.

4.1 Recolección de Datos

Las muestras se recolectaron en diversas condiciones de tráfico. El dataset incluye principalmente escenarios urbanos para capturar una variabilidad representativa de las situaciones de conducción en la ciudad. Las clases están balanceadas con una distribución de 50% para entrenamiento y 50% para prueba.

4.2 Descripción del Dataset

Para este propósito, se empleó un escáner láser, específicamente el S3000 de la empresa SICK. Este dispositivo captura imágenes del entorno del conductor, las cuales se procesan para identificar tres regiones dentro de la distancia de frenado del vehículo: izquierda, central y derecha de la calle. Los datos recopilados se utilizan para crear conjuntos de entrenamiento y prueba, los cuales son analizados mediante bibliotecas de Deep Learning para extraer patrones y construir un modelo de detección de carriles. El esquema de trabajo se ilustra en la Fig. 1.



Fig.1. Esquema de integración del escáner S3000 y el Jetson Nano en el vehículo.

Posteriormente, se instala el programa RVIZ para visualizar en tiempo real las imágenes provenientes de los carriles, como se muestra en la Fig. 2.

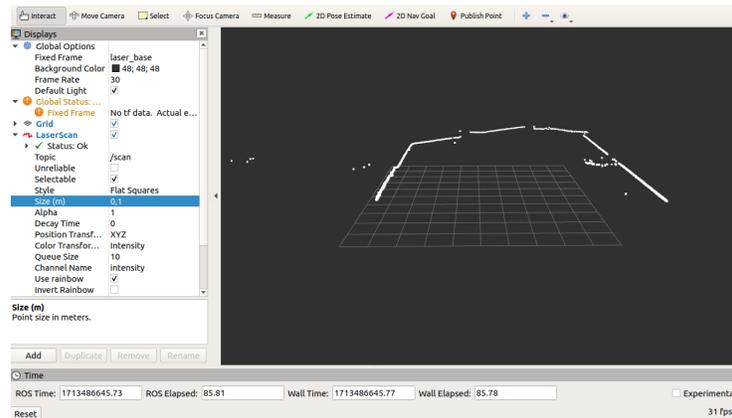


Fig. 2. Visualización del escaneo del S3000 en el programa RVIZ.

Se desarrolla una serie de pasos para extraer información suministrada por el sensor S3000:

1. Se generan archivos bag para los carriles mediante el sistema ROS.
2. Se desarrolla un programa escrito en Python para convertir los archivos bag en archivos CSV.
3. Los archivos CSV permiten establecer un conjunto de datos de 2900 ejemplos.
4. Finalmente, se genera un archivo de entrada con 2900 ejemplos y un archivo de salida correspondiente.

5 DESARROLLO DEL MODELO DE PREDICCIÓN

El modelo se entrenó utilizando el algoritmo de retropropagación con la función de pérdida de entropía cruzada. Se exploraron varios hiperparámetros, como la tasa de aprendizaje (0.01, 0.001), el número de épocas (10, 24) y el tamaño del lote (16, 32).

Este modelo proporciona resultados prácticos basados en los datos de entrada y salida. Cada ejemplo en el archivo de entrada consta de 760 columnas, debido a la resolución del escáner S3000 de 0.25° y un barrido de 190° ($760 = 190/0.25$). Por otro lado, el archivo de salida está compuesto por tres columnas y 2900 filas. La primera columna representa el carril izquierdo (CI), la segunda columna el carril central (CC) y la tercera columna el carril derecho (CD).

En la Figura 3, el gráfico muestra la exactitud del modelo durante el entrenamiento, alcanzando un valor de 0.95. Las pérdidas se estabilizan en la iteración 14 con un valor aproximado de 0.1.

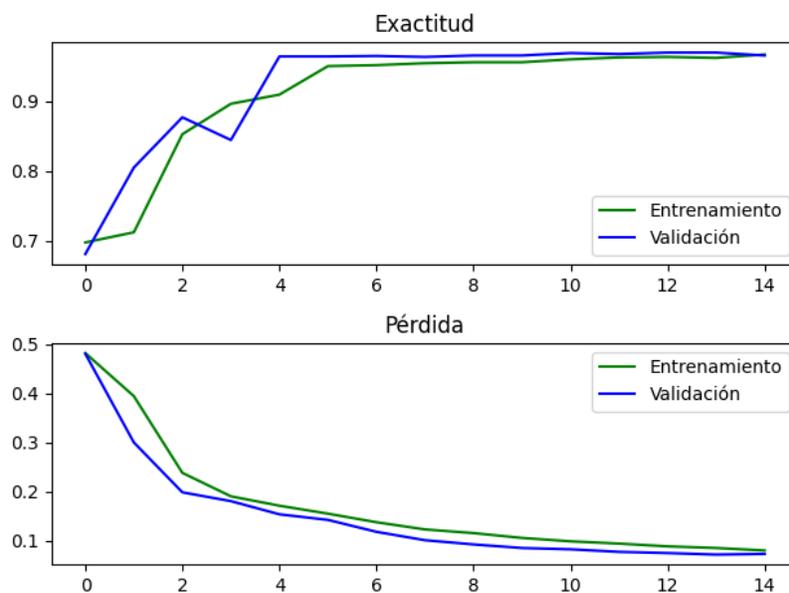


Fig. 3. Respuesta del entrenamiento de la red.

Para entrenar la red, se utilizó la herramienta TensorFlow [18]. Se propuso emplear una red neuronal de tres capas: la capa de entrada con 760 neuronas, la capa oculta con 150 neuronas de tipo sigmoide y la capa de salida con tres neuronas softmax.

6 ANÁLISIS DEL RENDIMIENTO DEL PREDICTOR MEDIANTE LA CURVA ROC EN LA DETECCIÓN DE CARRILES

La curva ROC, presentada en la Figura 4, es una herramienta gráfica que permite visualizar la sensibilidad frente a la especificidad para un sistema clasificador a medida que varía el umbral de discriminación.

Las clases se definen de la siguiente manera: la clase 0 corresponde a CI con un valor de 0.95, la clase 1 a CC con un valor de 0.92, y la clase 2 representa a CD con un valor de 0.89.

La curva ROC se implementó utilizando ejemplos, algoritmos y librerías de inteligencia artificial [19], permitiendo evaluar el rendimiento del predictor según el carril utilizado por el vehículo.

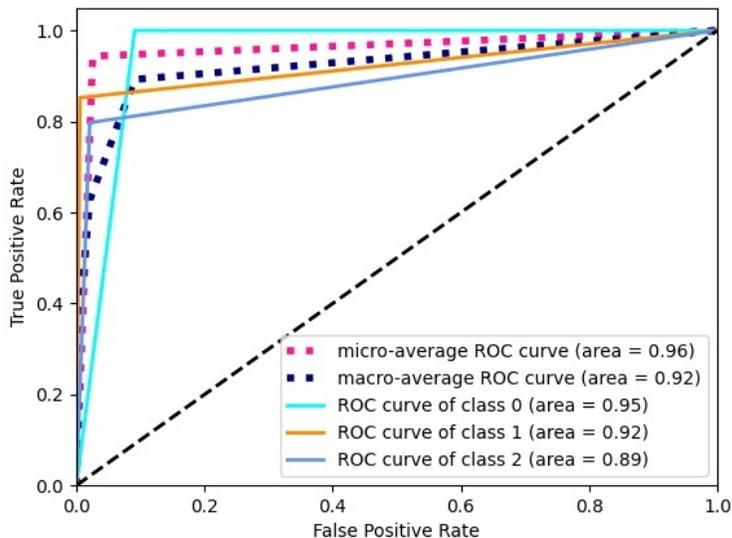


Fig. 4. Curva ROC de los tres casos.

7 CONCLUSIONES

La percepción vial y la detección de marcas de carril juegan un papel fundamental en la prevención de errores y en el respaldo a los conductores. Específicamente, la detección de carriles sirve como base para diversos sistemas avanzados de asistencia al conductor (ADAS).

Este estudio presenta una novedosa técnica para desarrollar un modelo de detección de carriles en vías no señalizadas, utilizando un sensor LIDAR montado en un vehículo. El escáner láser del LIDAR captura imágenes del entorno del conductor, que luego son procesadas para identificar los carriles izquierdo, central y derecho de la calzada. Estos datos se emplean para entrenar un modelo de detección de carriles mediante técnicas de Deep Learning, evaluando su efectividad mediante la curva ROC.

La integración de la tecnología LIDAR y el Deep Learning representa un avance significativo en la mejora de la seguridad vial, al proporcionar un sistema preciso y robusto para la detección de carriles en condiciones de tráfico no señalizado. Además, este trabajo contribuye al desarrollo de tecnologías de percepción del tráfico, abarcando la detección de obstáculos y la estructura vial, lo que constituye un aporte importante al campo de la conducción autónoma y la seguridad vial.

References

- [1] Debada E. and D. Gillet, "Virtual vehicle-based cooperative maneuver planning for connected automated vehicles at single-lane roundabouts," *IEEE Intelligent Transportation Systems Magazine*, vol. 10, no. AR- TICLE, pp. 35–46, 2018.
- [2] Hubmann C., J. Schulz, M. Becker, D. Althoff, and C. Stiller, "Automated driving in uncertain environments: Planning with interaction and uncertain maneuver prediction," *IEEE Transactions on Intelligent Vehicles*, vol. 3, no. 1, pp. 5–17, 2018.
- [3] Lefèvre, Stéphanie, Christian Laugier, and Javier Ibañez-Guzmán. "Exploiting map information for driver intention estimation at road intersections." In 2011 IEEE Intelligent Vehicles Symposium (IV), pp. 583-588. IEEE, 2011.
- [4] A. Mudgal, S. Hallmark, A. Carriquiry, and K. Gkritza, "Driving behavior at a roundabout: A hierarchical Bayesian regression analysis," *Transp. Res. Part D, Transp. Environ.*, vol. 26, pp. 20–26, 2014.
- [5] M. Zhao, D. Kathner, M. Jipp, D. Soffker, and K. Lemmer, "Modeling driver behavior at roundabouts: Results from a field study," in *Proc. 2017 IEEE Intell. Veh. Symp.*, 2017, pp. 908–913.
- [6] E. Ohn-Bar, A. Tawari, S. Martin, and M. M. Trivedi, "On surveillance for safety critical events: In-vehicle video networks for predictive driver assistance systems," *Comput. Vis. Image Understanding*, vol. 134, pp. 130–140, 2015.
- [7] A. Alahi, K. Goel, V. Ramanathan, A. Robicquet, L. Fei-Fei, and S. Savarese, "Social LSTM: Human trajectory prediction in crowded spaces," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, 2016, pp. 961–971.
- [8] F. Vicente, et al., Driver gaze tracking and eyes off the road detection system, *IEEE Transactions on Intelligent Transportation Systems* 16 (4) (2015) 2014e2027.
- [9] Athish S. R., Hansini R., Nithilan V., Vidhula S. G., Vijesh V., Renjith P.N. "Multi-Modal Driver Behavior Analysis and Speed Estimation using Fusion of Computer Vision and InCar Sensor Data" 2024 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS)
- [10] B. He, et al., Lane marking detection based on Convolution Neural Network from point clouds, in: *Intelligent Transportation Systems (ITSC), 2016 IEEE 19th International Conference on*, IEEE, 2016.
- [11] Jun Li, et al., Deep neural network for structural prediction and lane detection in traffic scene, *IEEE Transactions on Neural Networks and Learning Systems* 28 (3) (2016) 690e703.
- [12] Yang Xing, Chien Lv and Dongpu Cao. Advanced Driver Intention Inference Theory and Design. Editorial Project Manager: Gabriela D. Capille. U.S.A 2020. Cp.3 p.58.
- [13] Kunsong Shi , Yuankai Wu, Haotian Shi, Yang Zhou, Bin Ran. An integrated car-following and lane changing vehicle trajectory prediction algorithm based on a deep neural network. *Physica A: Statistical Mechanics and its Applications*. Volume 599, 1 August 2022, 127303. <https://doi.org/10.1016/j.physa.2022.127303>.
- [14] Rubén Izquierdo, Álvaro Quintanar, David Fernández Llorca, Iván García Daza, Noelia Hernández, Ignacio Parra, Miguel Ágil Sotelo. Vehicle trajectory prediction on highways using bird eye view representations and deep learning. Published online 20 July 2022. <https://doi.org/10.1007/s10489-022-03961-y>.
- [15] Stephan Matzka, Andrew M. Wallace, and Yvan R. Petillot. Efficient Resource Allocation for Attentive Automotive Vision Systems *IEEE TRANSACTIONS ON*
- [16] Streubel T. and K. H. Hoffmann, "Prediction of driver intended path at intersections," in *Proc. IEEE Intell. Vehicles Symp.*, Jun. 2014, pp. 134–139.

- [17] Artiom Basulto-Lantsova, Jose A. Padilla-Medina, Francisco J. Perez-Pinal, Alejandro I. Barranco-Gutierrez. Performance comparative of OpenCV Template Matching method on Jetson TX2 and Jetson Nano developer kits. Authorized licensed use limited to: MINCYT. Downloaded on October 17,2022 at 18:10:49 UTC from IEEE Xplore. Restrictions apply.
- [18] Gulli Antonio, Pal Sujit (2017). Deep Learnig with Keras.Implement neural networks with Keras on Theano and Tensor Flow. Cap-1, pag-50-53. Birmingham. Mumbai. Packt>.
- [19] Bowles Michael.(2015). Machine Learning in Python. Cap-3, pag 92-95. Indianapolis. USA. Wiley.