

Desarrollo de un procedimiento para detectar carriles en vías no señalizadas utilizando visión artificial

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@hotmail.com

Abstract. Los accidentes de tráfico son causados principalmente por errores humanos como la falta de atención, mal comportamiento o distracción. Muchas empresas han desarrollado técnicas para mejorar la seguridad en la conducción y reducción de siniestros viales. El contexto del tráfico es el principal estímulo para la intención del conductor y puede ser utilizado para predecir una acción futura. Este trabajo desarrolla un procedimiento que permite detectar el carril en vías no señalizadas empleando visión artificial. Se utiliza una cámara de video en un vehículo para obtener imágenes del campo visual del conductor. En los fotogramas obtenidos se establecen cinco regiones comprendidas dentro de la distancia de frenado del vehículo. La primera región se encuentra a la izquierda del automóvil. Las tres siguientes en el centro y la última a la derecha. Luego, se incorporan librerías de deep learning encargadas de analizar estas imágenes. Se utiliza el operador de divergencia en histogramas para cuantificar texturas entre regiones. Los valores obtenidos permitieron clasificar semejanzas entre regiones. Por ejemplo, en el caso donde el automóvil viaja en el carril central se obtienen cinco texturas semejantes. En los casos de traslado en el carril derecho o izquierdo la divergencia aumentaba respecto a las regiones centrales. De esta manera se propone estimar la ubicación del carril del vehículo utilizando como base de comparación los valores de la divergencia entre regiones. Este trabajo realiza un aporte a las tecnologías relacionadas a la percepción del tráfico donde se incluyen la detección de obstáculos, estructura viales y detección de carril.

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

1 INTRODUCCIÓN

Conducir vehículos es una tarea altamente especializada que requiere un amplio conocimiento del tipo de vía y el contexto en el que se mueve. Este conocimiento

permite a los conductores navegar con seguridad por áreas de mucho tráfico. Si bien puede convertirse en una tarea trivial para un conductor humano experimentado, comprender adecuadamente las intenciones de otros conductores, sigue siendo un tema de investigación para los Advanced Driver Assistance Systems (ADAS). Los sistemas ADAS brindan un soporte al conductor mediante la implementación de sensores auxiliares dentro de vehículo para el apoyo al conductor en determinadas situaciones de manejo. Conllevan a menudo aspectos de seguridad, dado que la mayoría de accidentes están provocados por error humano. En este sentido, si el vehículo es autónomo e interactúa con otros conducidos por personas, es aún más importante poder construir modelos y mecanismos que detecten y discriminen el comportamiento de todos los vehículos involucrados en una situación de tráfico compleja. Las intersecciones presentan desafíos especiales porque involucran la coordinación entre vehículos. Por lo tanto, es necesario que cada uno cuente con modelos que permitan desarrollar una estrategia de planificación del movimiento para la toma de decisiones adecuadas. El problema de coordinar el tráfico para mejorar la seguridad puede resolverse con estrategias basadas en comunicación vehículo a vehículo o vehículo a infraestructura [1]. Las técnicas y estrategias desarrolladas en estos trabajos no resuelven situaciones que se pueden presentar en un escenario vehicular desconectado de este tipo de tecnología. Por ejemplo, en [2] se presentan estrategias de resolución en la detección y predicción de trayectorias de vehículos involucrados en intersecciones. Allí se demuestra que la capacidad de predecir acciones futuras de los conductores antes de ingresar o detenerse en una intersección es fundamental para los sistemas ADAS. Para el cálculo de la intención de un conductor que maneja en el tráfico complejo, se utilizan por separado tres aproximaciones. La primera, es el desarrollo de un modelo de interacción integrado con el ambiente que interprete señales, objetos presentes como lo destaca [3]. La segunda, analiza la predicción de la intención de maniobra de automovilistas mediante la sincronizando de la información proveniente de un GPS, la codificación de ruedas [4][5], datos inerciales de sensores ubicados en el automóvil e integrados con un sistema de visión artificial [6][7]. La tercera, obtiene datos relevantes dentro de la cabina del automóvil tales como: posición de las manos en el volante, ubicación de los pies en los pedales, posición de los ojos, movimiento de la cabeza del conductor, activación del guiño de giro [8]. Este trabajo desarrolla un procedimiento que permite detectar el carril en vías no señalizadas empleando visión artificial. Se utiliza una cámara de vídeo en un vehículo para obtener imágenes del campo visual del conductor.

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 intención acción avanzada, robusta y precisa es desarrollar sistemas de fusión de sensores multimodales. El rendimiento en pro-

cesos de detección utilizando dichas tecnologías se puede mejorar con técnicas de integración. 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 [9]. El trabajo [10] muestra un sistema de detección de carril basado en redes neuronales convolucionales o CNN y red neuronal recurrente RNN. En [11] 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 [12] 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 [13] 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 desarrolló un enfoque orientado al comportamiento de los conductores en entornos estructurados, es decir, aquellas situaciones donde se encuentran estrictamente definidos carriles o semáforos [14] y [15], pero hay menos enfoques en escenas de carreteras no señalizadas. Estas últimas comúnmente no tienen infraestructura vial para hacer cumplir un comportamiento estricto y ordenamiento de vehículos. Este trabajo desarrolla un procedimiento que permite detectar el carril en vías no señalizadas empleando visión artificial. Se utiliza una cámara de vídeo en un vehículo para obtener imágenes del campo visual del conductor. En los fotogramas se establecen cinco regiones comprendidas dentro de la distancia de frenado del vehículo. La primera región se encuentra a la izquierda del automóvil. Las tres siguientes en el centro y la última a la derecha. Luego, se incorporan librerías encargadas de analizar texturas en imágenes. Se utiliza el operador de divergencia en histogramas para cuantificar texturas entre regiones. Los valores obtenidos permitieron clasificar semejanzas entre regiones. Por ejemplo, en el caso donde el automóvil viaja en el carril central se obtienen cinco texturas semejantes. En los casos de trasladarse en el carril derecho o izquierdo la divergencia aumentaba respecto a las regiones centrales. De esta manera se propone estimar la ubicación del carril del vehículo utilizando como

base de comparación los valores de la divergencia entre regiones. Este trabajo realiza un aporte a las tecnologías relacionadas a la percepción del tráfico donde se incluyen la detección de obstáculos, estructura viales y detección de carril.

4 DETECTOR DE CARRIL

Utilizando técnicas de procesamiento de imagen se desarrolla un detector de carril vehicular mediante el análisis de histogramas y cálculo de texturas. Las Fig. 1, 2 y 3. muestran fotogramas de una avenida no señalizada. Se establecen cinco regiones denominadas A0, A1, A2, A3 y A4 ubicadas entre las distancias de frenado del vehículo. También se implementa una ventana representativa del campo visual del conductor. Seguidamente, se utiliza un modelo de red neuronal para detectar objetos. Debido a la necesidad de evitar análisis de texturas donde se solapan superficies de figuras con el piso de la avenida en las áreas A0, A1, A2, A3 y A4.




Fig. 1. Vehículo transitando en el carril izquierdo.




Fig. 2. Vehículo transitando en el carril central.

Se utiliza el descriptor Local Binary Pattern(LBP) para clasificar e identificar automáticamente texturas y patrones dentro de áreas [16]. El LBP es un descriptor que se calcula sobre cada punto de la imagen codificando en un




Fig. 3. Vehículo transitando en el carril derecho.

número la relación que guarda cada pixel respecto de sus vecinos. Una variante ampliamente usada de los LBP son los patrones uniformes. Seleccionando solo patrones uniformes se logra reducir la longitud del vector característico y mejorar los clasificadores, adicionalmente, se puede aplicar esta técnica para obtener invarianza ante rotaciones. Un LBP es uniforme (LBPU) cuando contiene como máximo dos transiciones de 1 a 0 o de 0 a 1 por ejemplo: 000100 posee dos transiciones (es LBPU), 010101001 posee siete transiciones (no es LBPU). Al calcular el histograma del LBP, se le asigna un valor separado por cada patrón uniforme y todos los patrones no uniformes son asignados a un valor único. Usando esta técnica se logra reducir la longitud de un vector desde 256 a 59 espacios. Se implementa la librería skimage para facilitar el cálculo del descriptor LBPU. Los histogramas LBPU de los carriles izquierdo, central y derecho se visualizan en las Fig. 4, 5 y 6.




Fig. 4. Histograma LBPU para el carril izquierdo.

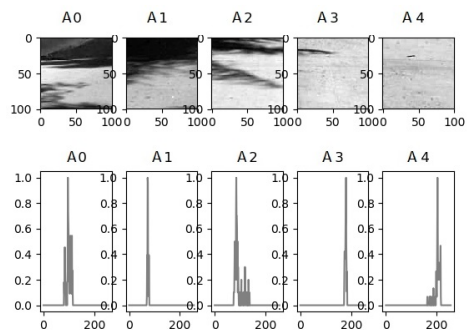


Fig. 5. Histograma LBP para el carril central.




Fig. 6. Histograma LBP para el carril derecho.

Luego, se recurre al operador matemático denominado divergencia (Kullback-Leibler) como herramienta de comparación entre histogramas. Seguidamente, se calcula la divergencia entre el área A2 con las áreas A0, A1, A3 y A4. Finalmente, los resultados obtenidos se muestran en las tablas 1, 2 y 3.

5 ANÁLISIS DE RESULTADOS

La tabla 1 indica mayor divergencia en la primera línea. Sugiriendo que el vehículo se encuentra en el carril izquierdo. La Fig. 7 visualiza los datos de la tabla 1.

En la tabla 2 se observa menor ganancia de información en la cuarta línea. Sugiriendo que el vehículo se encuentra en el carril derecho. La Fig. 8 muestra los datos de la tabla 2.

La tabla 3 evidencia mayor divergencia en la cuarta línea, pero en conjunto los valores son significativamente bajos. Finalmente, la Fig. 9 representa los datos de la tabla 3.

| Columna | Área | Kullback-Leibler-divergencia |
|---------|-----------|------------------------------|
| 1 | A0 and A2 | 0.11486 |
| 2 | A1 and A2 | 0.00636 |
| 3 | A3 and A2 | 0.00593 |
| 4 | A4 and A2 | 0.00213 |

Table 1. Vehículo transitando en el carril izquierdo.

| Columna | Area | Kullback-Leibler-divergencia |
|---------|-----------|------------------------------|
| 1 | A0 and A2 | 0.02417 |
| 2 | A1 and A2 | 0.01757 |
| 3 | A3 and A2 | 0.01102 |
| 4 | A4 and A2 | 0.12116 |

Table 2. Vehículo transitando en el carril derecho.

| Columna | Area | Kullback-Leibler-divergencia |
|---------|-----------|------------------------------|
| 1 | A0 and A2 | 0.037 |
| 2 | A1 and A2 | 0.02713 |
| 3 | A3 and A2 | 0.05223 |
| 4 | A4 and A2 | 0.07251 |

Table 3. Vehículo transitando en el carril central.




Fig. 7. Figura representativa de la tabla 1.




Fig. 8. Figura representativa de la tabla 2.




Fig. 9. Figura representativa de la tabla 3.

El concepto de divergencia es utilizado en éste trabajo para realizar comparaciones entre texturas. Es decir por ejemplo: en dos texturas iguales el resultado de la divergencia es próximo a cero. Los códigos fuentes utilizados se pueden obtener en [17].

6 CONCLUSIONES

Se desarrolló un procedimiento para extraer información relevante en fotogramas mediante visión por computadora. La librería del modelo de red neuronal se utilizó para detectar el momento adecuado donde las áreas A0, A1, A2, A3 y A4 estén libres de objetos que interfieran con la textura del piso de la avenida. Es decir, no exista solapamiento de otros objetos que puedan interferir en el cálculo de la divergencia.

Se utiliza una cámara de vídeo en un vehículo para obtener imágenes del campo visual del conductor. Se establecen en los fotogramas, cinco regiones ubicadas dentro de la distancia de frenado del vehículo. La primera región se encuentra a la izquierda del automóvil es decir A0. Las tres siguientes A1, A2 y A3 se ubicaron en el centro y A4 a la derecha.

Se utiliza el operador de divergencia en histogramas para cuantificar texturas entre regiones. Los valores obtenidos permitieron clasificar semejanzas entre regiones. Por ejemplo, en el caso donde el automóvil viaja en el carril central se obtuvo valores de texturas semejantes. En los casos de trasladarse en el carril derecho o izquierdo la divergencia aumentó respecto a la región A2. De esta manera se propone estimar la ubicación del carril del vehículo utilizando como base de comparación los valores de la divergencia entre regiones. El procedimiento propuesto se puede combinar con sistemas ADAS para mejorar la percepción vehicular utilizando por ejemplo la fusión de sensores multimodales.

Este trabajo realiza un aporte a las tecnologías relacionadas a la percepción del tráfico donde se incluyen la detección de obstáculos, estructura viales y detección de carril.

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] 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.
- [10] 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.
- [11] 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.
- [12] 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>.
- [13] 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>.
- [14] Stephan Matzka, Andrew M. Wallace, and Yvan R. Petillot. "Efficient Resource Allocation for Attentive Automotive Vision Systems" *IEEE TRANSACTIONS ON*
- [15] Streubel T. and K. H. Hoffmann, "Prediction of driver intended path at intersections," in *Proc. IEEE Intell. Vehicles Symp.*, Jun. 2014, pp. 134–139.
- [16] Kuan Li;Fuyong Zhang;Jie Xiao. "Maximum Entropy based Local Multiple Patterns for Texture Classification." *2021 IEEE 6th International Conference on Signal and Image Processing (ICSIP)*.
- [17] Vazquez Raimundo:
<https://drive.google.com/file/d/1plhn7GTi6eIsIcPhqzaOVLHEHqthVail/view>