

10.30972/fac.3306844

DetECCIÓN DE CARRIL VEHICULAR UTILIZANDO EL YOLO COMO SENSOR

Vázquez, R.¹, Torres, C., Mariguetti, G. S. y Robledo Sanches, A. (*)

Resumen

Se desarrolla un procedimiento encargado de detectar vehículos circulando por carriles en una avenida. Se utiliza el programa YOLO como sensor de objetos. Mediante la integración del YOLO y un programa de visión artificial se facilita el análisis de información en un área dentro de un fotograma. Se dividió la avenida en tres carriles denominados: carril izquierdo (CI), carril central (CC) y carril derecho (CD). Se establece en el fotograma un área rectangular de base y altura conocida. Seguidamente, el YOLO detecta todos los objetos en el fotograma. La información recolectada se agrupa en una lista junto a sus coordenadas. Mediante un algoritmo, se analiza dicha lista para detectar los vehículos pertenecientes al área de trabajo. Los límites de cada carril CI, CC y CD están comprendidos sobre la base del área rectangular. Las posiciones, pertenecientes a la lista de automóviles, se comparan con los límites de los carriles CC, CI y CD. El resultado de las comparaciones permite reconocer vehículos pertenecientes a los carriles CC, CI y CD dentro de una región del fotograma.

Palabras clave: YOLO, sensor de tráfico, detector de carril.

Abstract

A procedure in charge of detecting vehicles circulating in lanes on an avenue is developed. It consists of using the YOLO program as an object sensor. Through the integration of YOLO and an artificial vision program known by the name OPenCV,

1. Grupo Universitario de Automatización de la Universidad Tecnológica Nacional (Facultad Regional de Resistencia). E-mail: ray_vazquez_2005@hotmail.com

(*) Cómo citar este artículo: Vázquez, R., Torres, C., Mariguetti, G. S. y Robledo Sanches, A. (2023). Detección de carril vehicular utilizando el YOLO como sensor. Revista Extensionismo, Innovación y Transferencia Tecnológica: claves para el desarrollo, 8(1), 7 - 14. <http://dx.doi.org/10.30972/fac.3306844>

the analysis of information within a frame is facilitated. Then, the avenue was divided into three lanes called: left lane (CI), central lane (CC) and right lane (CD). A rectangular area of known base and height was established on the frame. The YOLO then detects all objects in the frame. The collected information is grouped in a list along with its coordinates. Using an algorithm, this list is analyzed to detect the objects belonging to the work area. The variation ranges of each lane are included on the basis of the rectangular area. Finally, the positions of the object list are compared with the variation ranges of each lane at the base of the rectangle. In this way, it is possible to recognize vehicles belonging to lanes within an area of the frame.

Keywords: YOLO, traffic sensor, lane detector.

Introducción

La conducción de vehículos es una tarea altamente especializada que requiere amplia comprensión del tipo de camino y del contexto en que se mueve. Este conocimiento permite a los conductores navegar con seguridad a través de zonas de alta densidad de tráfico. Si bien puede convertirse en una tarea trivial para un conductor humano experimentado, entendiendo adecuadamente las intenciones de otros conductores, sigue siendo un tema de investigación para sistemas avanzados de asistencia al conductor o ADAS. En este sentido, si el vehículo es autónomo e interactúa con otros conducidos por personas, es aún más importante poder construir modelos que detecten y discriminen el comportamiento de todos los vehículos involucrados en una situación de tránsito complejo. Las intersecciones presentan desafíos especiales porque implica una coordinación entre los vehículos. Es necesario entonces que cada uno posea modelos que permitan desarrollar una estrategia de planificación de movimientos para la toma de decisiones adecuadas. Por ejemplo, en la coordinación del tráfico en una intersección o glorieta puede resolverse con estrategias basadas en la comunicación de vehículo a vehículo, o de vehículo a infraestructura (Debada et al., 2018).

Los investigadores Hubmann et al. (2018) presentan estrategias de resolución en detección y predicción de trayectorias de vehículos involucrados en intersecciones. Allí se muestra que la posibilidad de predecir acciones futuras de 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 tres aproximaciones. La primera es la fabricación de un modelo de interacción integrado con el ambiente que interprete señales, objetos presentes como lo destaca Lefèvre et al. (2011). La segunda analiza el camino de cada vehículo considerando posibles destinos y una función de recompensa por cada uno, (Galceran et al., 2015). Un tercer acercamiento es concentrar los esfuerzos en la predicción de los siguientes movimientos basados en los datos pasados.

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.

También se pueden destacar trabajos de investigación que se centran en obtener datos relevantes dentro de la cabina 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 (Vicente et al., 2015). 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 (He et al., 2016). En el siguiente trabajo Li et al. (2016) se propone un sistema de detección de carril basado en redes neuronales convolucionales o CNN y red neuronal recurrente RNN. En este sentido Yang et al. (2020) proponen un modelo de fusión de datos encargados de medir: características cinemáticas, visión artificial, interpretación de gestos del conductor utilizando algoritmos de Deep Learning. La predicción de la trayectoria de los vehículos es esencial para la seguridad de las maniobras y la eficiencia del control de conducción automatizada. Los procesos de seguimiento de automóviles y cambio de carril generalmente se estudian en forma separada, ignorando las dependencias de estos dos comportamientos. Para remediar este problema, el siguiente trabajo de Kunsong et al. (2022) proponen definir una trayectoria integrada de dos dimensiones basada en el modelo denominado aprendizaje profundo que permite predecir comportamientos combinados de intenciones. Finalmente, el trabajo de Izquierdo et al. (2022) presenta un método novedoso para predecir trayectorias de vehículos en escenarios vehiculares complejos utilizando redes neuronales convolucionales.

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 (Stephan et al., 2012; Streubel et al., 2014), 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. Por lo tanto, existe una amplia gama de estilos de manejo que un conductor puede realizar al atravesar intersecciones o glorietas, lo que aumenta la complejidad del análisis. El procedimiento utilizado en este trabajo consiste en integrar un software de visión artificial con una librería de detección de objetos para extraer información vehicular relevante en fotogramas.

Materiales y Método

Se utiliza un hardware genérico adaptado en tareas de inteligencia artificial al borde denominado Jetson Nano como lo detalla Artiom et al. (2022). Su arquitectura interna permite implementar algoritmos de visión artificial como por ejemplo OpenCV integrado al programa YOLO Yang et al. (2019). El YOLO identifica objetos en fotogramas como se visualiza en la figura 1.




Figura 1: Reconocimiento de objetos utilizando el programa YOLO.

El YOLO extrae del fotograma información de los objetos y luego los agrupa en una lista. El YOLO detecta: objetos, la tasa de acierto y las coordenadas en el fotograma. La figura 1 muestra objetos en el fotograma tales como: carteles de propagandas, peatones transitando en la vereda, animales, plantas etc. Se hace necesario introducir un algoritmo de filtrado dentro del programa de visión artificial para detectar vehículos en un área específica del fotograma.

Se desarrolla un algoritmo de filtrado implementado en un programa de visión artificial para facilitar la detección de vehículos en carriles:

- Se divide la avenida en tres carriles denominados: izquierdo (CI), central (CC) y derecho (CD).
- Se establece un área rectangular de base y altura conocida en el fotograma.
- Se obtiene del YOLO una lista de todos los objetos y sus coordenadas dentro del fotograma.
- Se comparan las coordenadas de cada vehículo, que pertenece al área

rectangular, con los rangos de variación de CI, CC y CD.

- Los vehículos, cuyas coordenadas estén dentro del rango de carril analizado, serán definidos como perteneciente al CI, CC o CD.

Resultados

La figura 2 muestra dos áreas de trabajo establecidas en el fotograma. Seguidamente, se dividió la avenida en CI, CC y CD. También, se plantea la posibilidad de definir otra área de trabajo como por ejemplo el carril denominado carril de entrada o CE.



Figura 2: Áreas de trabajo para detectar el carril vehicular.

La figura 3 muestra las coordenadas de cada vehículo apuntando a la base del área rectangular. El rango de variación de cada carril está comprendido dentro de la base del área rectangular.




Figura 3: Detector de carril vehicular dentro de un área rectangular.

No se contempla los objetos tales como: semáforos, lámparas, peatones, ciclistas, plantas y animales. Luego, las coordenadas de los vehículos, que estén incluidos en el área de trabajo, se comparan con la base del rectángulo de la figura 3. Cada carril tiene su rango de variación dentro de la base. Las coordenadas de los vehículos comprendidos dentro del rango CI, CC o CD se toman como pertenecientes a dicho carril. El algoritmo junto a los resultados del procesamiento digital de fotogramas mostrados en este trabajo se pueden obtener en Vázquez (2022).

Conclusiones

Se desarrolló un procedimiento encargado de detectar vehículos en carriles en una avenida. Se utilizó el programa YOLO como sensor de objetos. Solo se contempló la información relacionada a autos, motocicletas y camiones. Se dividió la avenida en tres carriles denominados: CI, CC y CD. Los rangos de variación de cada carril están definidos en la base rectangular en un área del fotograma. Mediante un algoritmo, se analizó una lista de vehículos y sus coordenadas proporcionadas por el YOLO. Luego se compararon las coordenadas con CI, CC y CD. Cada carril tiene su rango de variación dentro de la base rectangular. Las coordenadas de los vehículos comprendidos dentro del rango CI, CC o CD se toman como pertenecientes a dicho carril. La detección de carril de vehículos circulando en la vía pública representa una fuente de información muy importante en tareas de detección de intención acción de conductores circulando en un ambiente vehicular complejo.

Trabajo Futuro

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, 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. Por lo tanto, existe una amplia gama de estilos de manejo que un conductor puede realizar al atravesar intersecciones o rotondas. Esto se debe a la estructura no lineal de la trayectoria y métodos de seguimiento basados en modelos físicos estándar de baja exactitud. Las rotondas son utilizadas en el mundo como una intersección no señalizada debido a su alto rendimiento en áreas de tráfico medio o bajo. Los mismos tienen varios diseños y características constructivas; pueden ser tangenciales o radiales. Las tangenciales fomentan la velocidad y se combinan con una buena visibilidad. El procedimiento utilizado en este trabajo permitirá implementar una ventana donde se analiza el comportamiento de las variables de posición de los vehículos en cada carril en una avenida. La figura 4 muestra una ventana ubicada a

40 metros de la entrada de una rotonda y en su interior se obtendrá parámetros de posición mediante el programa YOLO.




Figura 4: Esquema simplificado de la toma de datos.

Se podrá establecer las posibles maniobras futuras utilizando el criterio de detección de carril para establecer las siguientes intenciones de giro: seguir derecho (SD), giro a la derecha (GD) o giro a la izquierda (GI).

Referencias

- Artiom Basulto-Lantsova, J. A., Padilla Medina, F. J., Perez Pinal, A. I., Barranco Gutierrez (2022). 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.
- Debada E. and D. Gillet (2018). “Virtual vehicle-based cooperative maneuver planning for connected automated vehicles at single-lane roundabouts,” IEEE Intelligent Transportation Systems Magazine, vol. 10, no. ARTICLE, pp. 35–46.
- Galceran E., A. G. Cunningham, R. M. Eustice, and E. Olson (2015). “Multi-policy decision-making for autonomous driving via changepoint-based behavior prediction,” in Proceedings of Robotics: Science and Systems (RSS), Rome, Italy, July 2015.
- He, B. et al. (2016) Lane marking detection based on Convolution Neural Network from point clouds, in: Intelligent Transportation Systems (ITSC), 2016 IEEE 19th International Conference on, IEEE.
- Hubmann C., J. Schulz, M. Becker, D. Althoff, and C. Stiller (2018). “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.

Izquierdo, Á., Quintanar, D., Fernández, L., García Daza, I., Hernández, N., Parra, I., Sotelo, A. (2022). 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>.

Kunsong Shi , Yuankai Wu, Haotian Shi, Yang Zhou, Bin Ran (2022). 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>.

Li, Jun (2016). et al., Deep neural network for structural prediction and lane detection in traffic scene, IEEE Transactions on Neural Networks and Learning Systems 28 (3) 690e703.

Lefèvre, S., Laugier, C., and Ibañez-Guzmán, J. (2011). “Exploiting map information for driver intention estimation at road intersections.” In 2011 IEEE Intelligent Vehicles Symposium (IV), pp. 583-588.

Stephan Matzka, Andrew M. Wallace, and Yvan R. Petillot (2012) Efficient Resource Allocation for Attentive Automotive Vision Systems. IEEE Transactions on Intelligent Transportation Systems, Vol. 13, N° 2, June.

Streubel T. and K. H. Hoffmann (2014). “Prediction of driver intended path at intersections,” in Proc. IEEE Intell. Vehicles Symp., Jun. 2014, pp. 134–139.

Yang Li, Long Xin, Dameng Yu, Pengwen Dai, Jianqiang Wang, Shengbo Eben Li (2019). Pedestrian Trajectory Prediction With Learning-based Approaches: A Comparative Study. 2019 IEEE Intelligent Vehicles Symposium (IV) Paris, France. June 9-12, 2019.

Yang Xing, Chien Lv and Dongpu Cao (2020). Advanced Driver Intention Inference Theory and Design. Editorial Project Manager: Gabriela D. Capille. U.S.A 2020. Cp.3 p.58.

Vazquez R. (s/f) online https://drive.google.com/file/d/1MwY2_2_NKF5ZCKKPCICH5WePbIr7AiU/view?usp=sharing.

Vicente, F. et al. (2015). Driver gaze tracking and eyes off the road detection system, IEEE Transactions on Intelligent Transportation Systems 16 (4) 2014e2027.