

10.30972/eitt.g28238

Predicción de Intenciones de Conductores en Rotondas No Estructuradas mediante Detección de Vehículos con YOLO y Análisis Estadístico

Vázquez, R., Torres, C., Mariguetti, O., Gramajo, S. y Robledo Sanchez Alberto, A. A. (*)

Resumen

Este estudio aborda la complejidad de predecir las intenciones de los conductores en intersecciones no estructuradas, como rotondas sin señales de tráfico sin marcaciones viales. Estas situaciones presentan desafíos únicos para los sistemas avanzados de asistencia al conductor (ADAS) y los vehículos autónomos. A diferencia de autopistas con carriles y semáforos claramente definidos, las rotondas no reguladas exigen un análisis más sofisticado del comportamiento vehicular. El enfoque propuesto utiliza el modelo de detección de objetos YOLO para detectar vehículos en una rotonda y focaliza la detección en áreas específicas como las entradas y salidas, en lugar de analizar toda la escena, lo que mejora la precisión y eficiencia. Además, se aplica un sistema de seguimiento basado en centroides para evitar contar el mismo vehículo varias veces. Se definen seis zonas en la rotonda: tres para predecir el comportamiento de los conductores y tres para contar los vehículos que realmente toman una salida específica. El sistema también mide el tiempo de congestión en la rotonda cuando los vehículos permanecen inmóviles durante un tiempo determinado, proporcionando información clave para la gestión del tráfico. Los resultados muestran una tasa de acierto significativa en la predicción de las trayectorias vehiculares, aunque existen casos en los que la predicción no coincide con los movimientos reales de los vehículos, lo que sugiere la necesidad de mejoras en la precisión del algoritmo. El estudio también sugiere que la integración futura de modelos de aprendizaje automático podría mejorar notablemente el

1. Grupo Universitario de Automatización (GUDA). Universidad Tecnológica Nacional - Facultad Regional Resistencia. Autor de correspondencia: Vázquez, R. E-mail: ray_vazquez_2005@hotmail.com

(*) Cómo citar este artículo: Vázquez, R., Torres, C., Mariguetti, O., Gramajo, S., Robledo Sanchez Alberto, A. A. (2024). Predicción de Intenciones de Conductores en Rotondas No Estructuradas mediante Detección de Vehículos con YOLO y Análisis Estadístico. Revista Extensionismo, Innovación y Transferencia Tecnológica: claves para el desarrollo, 9(2), 61-67. <https://doi.org/10.30972/eitt.g28238>

rendimiento del sistema. Finalmente, el trabajo ofrece un enfoque novedoso para mejorar la seguridad y eficiencia del tráfico en rotondas, a pesar de las limitaciones encontradas, como el ángulo de captura de video.

Palabra clave: comportamiento predictivo del conductor, intersecciones no estructuradas, rotondas.

Abstrac

This study explores the complexity of predicting driver intentions in unstructured intersections, such as roundabouts without traffic signs or lane markings. These scenarios pose unique challenges for advanced driver assistance systems (ADAS) and autonomous vehicles. Unlike highways with well-defined lanes and traffic signals, unregulated roundabouts require a more detailed analysis of vehicle behavior. The proposed approach uses the YOLO object detection model to identify vehicles in a roundabout, focusing on specific areas like entrances and exits, rather than analyzing the entire scene, which improves accuracy and efficiency. A centroid-based tracking system is also implemented to avoid counting the same vehicle multiple times. Six zones are defined within the roundabout: three to predict driver behavior and three to count vehicles exiting the roundabout. The system also measures congestion time when vehicles remain stationary for a certain period, providing key information for traffic management. Results show a significant accuracy rate in predicting vehicle trajectories, though there are cases where predictions do not fully match actual vehicle movements, highlighting the need for algorithm improvements. The study also suggests that integrating machine learning models in the future could significantly enhance system performance. Ultimately, the research presents an innovative approach to improving traffic safety and efficiency in roundabouts, despite certain limitations such as the video capture angle.

Keywords: predictive driver behavior, unstructured intersections, roundabouts.

Introducción

Conducir vehículos implica una comprensión profunda de las intenciones de los demás usuarios de la vía, lo que permite a los conductores maniobrar de manera segura en entornos de tráfico complejos. Aunque esta habilidad puede volverse instintiva para un conductor humano experimentado, predecir de forma precisa las intenciones de otros conductores sigue siendo un desafío para los sistemas avanzados de asistencia al conductor (ADAS) y, en mayor medida, para los vehículos

autónomos. Este problema ha sido ampliamente estudiado en autopistas, utilizando conjuntos de datos que se centran en intersecciones altamente estructuradas, con múltiples carriles y semáforos. Sin embargo, hay poca atención en las intersecciones más pequeñas y menos reguladas, donde a menudo no hay señales de tráfico ni marcaciones viales adecuadas. Navegar de manera segura en estos entornos dinámicos es igualmente crucial para el funcionamiento correcto de los vehículos autónomos. Una proporción significativa de accidentes ocurre en intersecciones, y el 47% de ellos se debe a errores de reconocimiento o de toma de decisiones por parte de los conductores Yang et al. (2020). En este artículo, proponemos un método que predice las intenciones de los conductores considerando la incertidumbre, lo que resulta en una salida multimodal sobre las rutas posibles que un conductor podría tomar. En una intersección, pueden existir múltiples trayectorias posibles, pero el promedio de dos rutas posibles puede no representar una solución válida. Por lo tanto, proponer y clasificar varias rutas posibles proporciona una mejor representación de las intenciones del conductor. La rotonda elegida para el estudio es de naturaleza no estructurada y a la ausencia de semáforos que indiquen el derecho de paso, lo que la convierte en una intersección altamente dinámicas y complejas. Esta dinámica dificulta la predicción de la ruta y la intención de un conductor en tales entornos, lo que resalta la importancia del método propuesto.

Definición del problema

En los últimos años, varios enfoques han sido propuestos para analizar el comportamiento de los conductores en entornos viales estructurados, como aquellos con carriles bien definidos o la presencia de semáforos Stephan et al. (2012) y Streubel et al. (2014). Sin embargo, las carreteras sin señalización explícita, como rotondas o intersecciones sin infraestructura vial estricta, presentan desafíos considerables que aún no han sido abordados en profundidad. La ausencia de regulación precisa en estos espacios permite a los conductores adoptar una amplia gama de estilos de manejo, lo que complica el análisis y la predicción de los movimientos vehiculares.

Este trabajo se centra en el análisis del comportamiento de los vehículos dentro de una rotonda, en la que las entradas y salidas no están claramente delimitadas por señales o dispositivos de control. La detección y el seguimiento de vehículos en estos entornos resultan fundamentales para mejorar tanto la seguridad como la eficiencia del tráfico. Para ello, se utiliza Python y OpenCV, herramientas ampliamente aplicadas en el procesamiento de imágenes y visión por computadora. En este caso, ambas se implementan para detectar y seguir automóviles y camiones en video mediante el modelo YOLO Chao et al. (2022), permitiendo una detección en tiempo real.

Posteriormente, se realiza un análisis estadístico de los vehículos que ingresan y

circulan en la rotonda, incluyendo sus intenciones de giro, lo que permite no solo el conteo de estos, sino también una predicción de sus trayectorias más probables: continuar recto, girar a la izquierda o a la derecha.

Configuración inicial

Nuestro enfoque propone dividir la rotonda en secciones manejables, identificando y limitando el área de interés a las zonas de entrada y salida. Esto permite una mayor precisión en la detección y seguimiento de los vehículos en estas áreas críticas, evitando que la detección de YOLO abarque toda la escena sin discriminación. Lo primero que se hace es cargar el modelo pre entrenado YOLOv3 con sus correspondientes archivos de configuración y pesos. Este modelo permite detectar vehículos de múltiples clases. Los nombres de las clases de los vehículos se almacenan en una lista.

Detección de vehículos

El archivo de video es procesado cuadro por cuadro, y el modelo YOLO realiza múltiples predicciones por cada fotograma, filtrando las detecciones con un umbral de confianza mayor a 0.7. A continuación, se calculan los centroides de los vehículos detectados y se almacenan sus dimensiones. Para evitar predicciones múltiples de un mismo vehículo, se implementa un algoritmo que utiliza la distancia euclidiana entre los centroides de cuadros consecutivos para mejorar la precisión.

Seguimiento de vehículos

El sistema captura datos en seis regiones. Las tres primeras, denominadas 1, 2 y 3, se encuentran en la entrada de la rotonda: la región 1 a la izquierda, la 2 en el centro y la 3 a la derecha. La región 4 identifica la intención de doblar a la derecha, la 5 indica la decisión de continuar recto y la 6 corresponde a la intención de doblar a la izquierda, como se muestra en la figura 1. Esta segmentación evita que un mismo vehículo sea identificado repetidamente en diferentes cuadros, lo que podría distorsionar el análisis de datos. Posteriormente, se calcula la distancia euclidiana entre los centroides actuales y los de cuadros anteriores. Por ejemplo, si un nuevo vehículo aparece cerca de otro previamente identificado, se asume que es el mismo y se le asigna su identificador correspondiente. De lo contrario, se le genera un nuevo identificador, permitiendo llevar un registro continuo de cada vehículo. Aunque existen márgenes de error debido a factores como la velocidad o las características del dispositivo de grabación, el modelo ha demostrado ser altamente preciso, sin errores significativos en este aspecto.




Fig. 1. Ilustración de las seis regiones propuestas

Contabilización del tiempo de espera

Además del conteo de los vehículos para la predicción de sus movimientos, se propone contabilizar el tiempo de congestión que experimentan los conductores. Para esto, una vez pasada una determinada cantidad de segundos (5 en este caso) en los cuales el automóvil no se mueve (su distancia euclidiana es la misma o prácticamente igual), se comienza un cronómetro que toma el período durante el cual este vehículo permanece inmóvil.

Actualización de las imágenes de los vehículos

Se lleva un registro de cada vehículo detectado junto con los últimos cuadros en el que fue visto. Si un automóvil no ha sido visto durante un número determinado de cuadros que en nuestro caso se optó por 30 cuadros, se elimina de la lista activa. Lo que mejora la eficiencia del algoritmo al remover vehículos que han salido de las seis regiones.

Propuesta de un sistema V2I de tráfico en rotondas

Al finalizar el análisis del video, los datos obtenidos se almacenan en un archivo CSV, facilitando la visualización y posterior procesamiento de los resultados. La finalidad de este trabajo es condensar esta información para su envío a un sistema

de comunicación vehicular V2I Junhyek et al. (2023), que alertará a los conductores sobre la congestión dentro de la rotonda antes de que ingresen y anticipará las intenciones de otros vehículos. Esto resulta especialmente útil en situaciones donde un conductor se aproxima a alta velocidad; el sistema puede advertirle de un alto nivel de congestión, permitiéndole desacelerar de manera anticipada y reducir el riesgo de accidentes. Además, anticipar las intenciones de giro de los vehículos antes de su ingreso a la rotonda optimiza la toma de decisiones, contribuyendo a una gestión más eficiente del flujo vehicular.

Resultados

Se proporciona una tabla donde se representa la información obtenida del algoritmo propuesto.

Tabla 1 representativa de los porcentajes de aciertos según las intenciones

Muestra	Autos	Posible izquierda	Posible recto	Posible derecha	Doblan izquierda	Siguen recto	Doblan derecha	Porcentaje correcto izquierda	Porcentaje correcto recto	Porcentaje correcto derecha	Tiempo de Congestión Total
1	29	12	10	7	14	8	7	86%	80%	100%	22s
2	32	14	12	6	17	9	6	82%	75%	100%	37s
3	33	15	12	6	18	9	6	83%	75%	100%	24s
4	31	13	11	7	16	8	7	81%	73%	100%	33s
5	33	15	12	6	18	9	6	83%	75%	100%	25s
6	30	13	11	6	15	9	6	87%	82%	100%	19s
7	53	23	19	12	28	13	12	82%	68%	100%	39s
8	57	24	20	14	29	14	14	83%	70%	100%	29s
9	54	23	19	13	28	13	13	82%	68%	100%	37s
10	56	24	20	13	29	14	13	83%	70%	100%	31s
11	56	23	19	14	28	13	15	82%	68%	93%	40s
12	58	24	20	14	29	14	15	83%	70%	93%	43s

La primera columna representa la muestra, la segunda columna visualiza el dataset de dicha muestra. Las columnas 3,4 y 5 dan la información de las posibles intenciones de maniobras. Las columnas 6, 7 y 8 son las verdaderas acciones de los conductores. Las columnas 9,10 y 11 dan el porcentaje de aciertos. La columna final determina el tiempo de congestión de vehículos dentro de la rotonda. El algoritmo propuesto puede ser obtenido en el repositorio (Andrés, 2024).

Conclusiones

El artículo resalta la complejidad de predecir las intenciones de los conductores en entornos no estructurados, como rotondas sin señales de tráfico ni marcaciones viales. Este tipo de intersecciones son más dinámicas y presentan una mayor incertidumbre en el comportamiento de los vehículos en comparación con autopistas o intersecciones reguladas. La utilización del modelo YOLO para la detección de vehículos dentro de una rotonda, focalizando la detección en áreas específicas como las entradas y salidas, permite una mayor precisión en el análisis del tráfico.

Esta innovación reduce la sobrecarga de información y mejora la eficiencia en el seguimiento de vehículos. Se implementó un sistema para el seguimiento de los vehículos mediante el cálculo de centroides y la aplicación de un método de tracking, lo que permite reducir la identificación duplicada de un mismo vehículo. Este sistema también facilita la predicción de las trayectorias de los vehículos dentro de la rotonda, mejorando la capacidad de anticipar las intenciones de los conductores. El modelo propuesto ofrece resultados positivos en la predicción de las trayectorias vehiculares. Sin embargo, existen casos en los que la predicción no coincide con el número real de vehículos que toman una determinada salida, lo que indica que aún hay espacio para mejorar la precisión del algoritmo. El sistema también contabiliza los tiempos de espera de los vehículos que permanecen detenidos en la rotonda, proporcionando información valiosa sobre la congestión vehicular. Este dato puede ser utilizado para alertar a los conductores mediante sistemas V2I, mejorando la gestión del tráfico. Una limitación clave del estudio es el ángulo de captura de video, que no era óptimo para un análisis perfecto. Esto podría haber afectado la precisión de las predicciones. Se menciona que un ángulo de visión de 90° hubiera sido ideal para mejorar el análisis.

Referencias

- Andrés, A. (s/f). Disponible en: <https://github.com/AldoOmarAndres/YoloTracker>
- Jiang, C., Zhang, H., Yue, Y., & Hu, X. (2022, March). AM-YOLO: Improved YOLOV4 based on attention mechanism and multi-feature fusion. In 2022 IEEE 6th Information Technology and Mechatronics Engineering Conference (ITOEC) (Vol. 6, pp. 1403-1407). IEEE.
- Jang, J., Baek, J., Lim, K., Ro, Y., Yoon, S., & Jang, S. (2023, February). A study on V2I based cooperative autonomous driving. In 2023 International Conference on Electronics, Information, and Communication (ICEIC) (pp. 1-3). IEEE.
- Matzka, S., Wallace, A. M., & Petillot, Y. R. (2012). Efficient resource allocation for attentive automotive vision systems. *IEEE Transactions on Intelligent Transportation Systems*, 13(2), 859-872.
- Streubel, T., & Hoffmann, K. H. (2014, June). Prediction of driver intended path at intersections. In 2014 IEEE Intelligent Vehicles Symposium proceedings (pp. 134-139). IEEE.
- Xing, Y., Lv, C., & Cao, D. (2020). *Advanced driver intention inference: Theory and design*. Elsevier.