

Estado de Arte: Visión de Máquina y Técnicas de Inteligencia Artificial para la Detección de Infracciones de Tránsito por Alta Velocidad

Toquica Hans  

Facultad de Ingeniería
Universidad Nacional de Colombia

Resumen—Los índices de accidentalidad en Colombia están creciendo, convirtiéndose en un problema de salud pública en la última década.[1] Los accidentes son causados generalmente por conductores imprudentes, tal es la razón por la que existen varias medidas para mitigar las muertes viales. [2] El control de velocidad es una de estas medidas y su aplicación se hace imponiendo multas de tránsito a los conductores que exceden los límites de velocidad. En este estado del arte se presenta la investigación realizada con respecto a los temas de automatización en este aspecto, específicamente usando visión de máquina.

Para el levantamiento del estado del arte, se tomaron documentos relacionados con el tema y se filtraron en varias etapas teniendo en cuenta diferentes parámetros. Se puede encontrar más detalle en este aspecto en la sección II.

La detección de vehículos, la detección de caminos y la estimación de velocidad fueron identificados como los principales trabajos en esta área. Adicionalmente un par de bases de datos fueron identificadas para realizar pruebas.

Abstract—Accidents on road in Colombia rates are growing, becoming a public health problem in the last decade.[1] The accidents are often caused by reckless drivers, therefore several programs define safety on-road measures to mitigate deaths on roads. [2] One of these measures is the speed control, a way to applying it is by impose traffic infractions to drivers who overpass speed limits. This state of the art presents research performed in regards of topics related to automation of this matter, specifically using computer vision.

Obtaining the state of the art was done by getting documents related with the topic and filtering through a couple of stages taking into account different parameters. Detailed information in this matter can be seen in section II.

Vehicle detection, road detection, speed estimation were identified as main works in this area. Also a couple of databases were identified for performing testing.

Index Terms—Vehicle detection, road segmentation, speed estimation, computer vision, artificial intelligence.

I. INTRODUCCIÓN

EN el diario vivir de la mayoría de personas es necesario transportarse de un punto a otro. La demanda en aumento del uso de la vía pública, sea por el crecimiento

Tipo de Infraestructura y Tráfico	Velocidad (km/h)
Possible conflicto entre transeúntes y vehículos	30
Intersecciones con posible impacto lateral entre vehículos	50
Vías con posible impacto frontal entre vehículos	70
Vías sin posible impacto frontal o lateral con vehículos (sólo impacto contra infraestructura)	100

Table I: Límites de velocidad por tipo de infraestructura y tráfico según *Vision Zero*.[4]

de la población o por la facilidad de acceso a vehículos de uso personal, sumado a la poca inversión en infraestructura vial, dan origen a embotellamientos en las vías principales de una ciudad.

La falta de cultura ciudadana junto con los embotellamientos ocasiona que los conductores adopten conductas agresivas en la vía con el fin de llegar con premura a su punto de destino, generando accidentes que algunas veces resultan en lesiones importantes para ellos mismos o para terceros, y en los peores de los casos, pérdida de su vida.[3]

El proyecto *Visión Cero* tiene como premisa que “la pérdida de la vida humana en tráfico es inaceptable”.[2] Este proyecto fue lanzado en 1995 en Suecia y en él se adoptan medidas para reducir los accidentes que ocasionan lesiones graves o la muerte en la vía. Una de las medidas importantes es clasificar la vía en relación a las interacciones de los actores y de acuerdo a esto establecer un límite de velocidad máxima de tránsito, tal y como lo muestra la Tabla I.

Con esto en mente, en la academia y con el avance tecnológico en materia de sistemas embebidos y comunicaciones se han propuesto sistemas integrados que interactuarían con las tecnologías emergentes en materia de movilidad. Tal es el caso de Elsagheer quien, en [5], muestra un sistema embebido que sería capaz de conectarse a distintos objetos integrados al transporte mediante una red vehicular Ad-Hoc. La comunicación se realizaría entre vehículos y señales de tránsito (*e.g.* semáforos), además se tendría la capacidad de conectarse a sistemas de posicionamiento global

☆ Dirección de e-mail: hmtoquicac@unal.edu.co

con el fin de estimar parámetros tales como la velocidad y se aplicarían infracciones de tránsito de forma automatizada. Sin embargo, este tipo de proyectos requieren una inversión estatal fuerte en materia de infraestructura vial, además de inversión individual de cada actor en la vía. Es necesario idear sistemas en materia de seguridad y control vial más aterrizzados a la actual realidad de la sociedad.

En el caso de la ciudad de Bogotá, Colombia, el proyecto Cámaras Salvavidas entró en operación en Octubre de 2019.[6] Este proyecto pretende adoptar medidas similares a las propuestas en el proyecto de Visión Cero, sin embargo, propone hacer gestión de las infracciones de tránsito por alta velocidad haciendo uso de instrumentos de captura de imágenes y de medición de velocidad. De tal manera, supone que la aplicación de infracciones reduciría a corto plazo la mala conducta de los infractores en cuanto a la alta velocidad en la vía pública y luego la accidentalidad sería reducida también.

Este mismo es el caso de varios países que han adoptado políticas importantes de monitoreo del camino basado en tecnologías de la información con el fin de reducir la accidentalidad y mejorar la fluidez del tráfico.

En general, los sistemas de medición de velocidad cuentan con al menos un elemento de medición de velocidad (un radar, líneas piezoelectricas en el suelo, *i.a.*) y un instrumento de captura de imágenes que permite hacer la identificación del vehículo infractor,[7]–[9] esta información es enviada a un centro de control de tránsito en el que se evalúa el caso para verificar la presunta infracción.[6]

En este trabajo se propone estimar la velocidad de los vehículos a partir de los instrumentos de captura de imágenes, sin hacer uso de los sensores adicionales. Con esto en mente, se revisó la literatura con el fin de obtener información acerca de los trabajos más relevantes que usan visión de máquina y técnicas de inteligencia artificial (IA) en escenas de tránsito y que tengan relevancia con la propuesta.

Para la revisión de la literatura se obtuvieron 178 artículos utilizando una ecuación de búsqueda. Estos artículos se fueron filtrando hasta obtener los artículos con más relevancia para el tema. Los filtros se hicieron con base en lecturas de primer y de segundo nivel. Finalmente se clasificaron según su categoría y las técnicas aplicadas. Más información con respecto a la metodología usada para la obtención de este estado de arte se puede encontrar en la sección II de este documento.

La afirmación más concluyente de este documento es que a pesar de que en la revisión bibliográfica se encontraron trabajos de estimación de velocidad aplicando técnicas de visión tridimensional, estos se basan en instrumentos de captura que generan nubes de puntos. No se encontraron trabajos que aplicaran técnicas de visión tridimensional a partir de instrumentos de captura de imágenes monoculares.

II. METODOLOGÍA

La recopilación de los documentos para hacer el levantamiento del estado del arte partió de establecer algunas ecuaciones de búsqueda de información para las bases de datos. Con ellas se consultaron dos bases de datos, *videlicet Scopus y Science Direct*.

Las ecuaciones de búsqueda que se utilizaron para consultar las bases de datos se obtuvieron a partir de diferentes fragmentos de la que se encuentra en Listing 1. Se hizo de esta manera debido a que las bases de datos imponen un límite de términos para refinar la búsqueda.

A los resultados de la búsqueda se les filtró (en las bases de datos mencionadas anteriormente), de tal manera que se admitieran resultados de máximo hace 10 años y se seleccionaron los que, por su nombre, implicaran una relevancia aceptable en el tema del que se trata en este documento.

Así pues, se seleccionaron 178 artículos (entre las dos bases de datos), los cuales se exportaron en formato *RIS* y se importaron posteriormente a **Mendeley Desktop**.

A estos documentos se le aplicó lectura de primer nivel, *i.e.* una aproximación inicial en la que se exploró el *corpus*, introducción y las conclusiones de cada documento. En esta lectura de primer nivel se descartaron artículos que no tuvieren relación con visión de máquina en aplicaciones de tránsito y artículos que si bien tienen cabida en la ecuación de búsqueda, no tienen relación directa con el tema de este trabajo (e.g. visión de máquina con cámara monocular dentro de vehículo para la detección de obstáculos y generación de trayectorias de conducción autónoma).

Al aplicar esta lectura de primer nivel se redujo el grupo a 80 documentos. A estos documentos se les aplicó la etiqueta “Lista_Filtrada” en el software mencionado anteriormente.

Listing 1: Ecuación de búsqueda.

```
("computer_vision" AND "urban_traffic") OR ("urban_traffic_control") OR ("machine_vision" AND "urban_traffic") OR ("computer_vision" AND "urban_transit") OR ("machine_vision" AND "urban_transit") OR ("computer_vision" AND vehicle_transit) OR ("machine_vision" AND vehicle_transit) OR (artificial_intelligence AND urban_traffic) OR (artificial_intelligence AND urban_transit) OR ("computer_vision" AND urban_traffic_control) OR ("machine_vision" AND urban_traffic_control) OR (ai AND urban_traffic_control) OR (ai AND transit_cameras) OR ("computer_vision" AND transit_cameras) OR ("computer_vision" AND car_plate_identification) OR ("machine_vision" AND car_plate_identification) OR ("computer_vision" AND vehicle_speed) OR ("machine_vision" AND vehicle_speed) OR ("computer_vision" AND transitViolation) OR ("machine_vision" AND transitViolation) OR ("artificial_intelligence" AND transitViolation) OR (ai AND transitViolation)
```

Posteriormente, a los elementos dentro de *Lista_Filtrada* se les hizo lectura de segundo nivel y se obtuvo un grupo

que se identificó con la etiqueta “Bibliografía_Anotada”. La lectura de segundo nivel consistió en leer de nuevo el resumen, introducción y conclusiones, pero además leer la metodología usada e identificar los resultados obtenidos. Esto se hizo con el fin de identificar las técnicas más ampliamente usadas y los nuevos métodos que se han identificado que poseen un desempeño comparable a los más populares.

De la lectura de segundo nivel se extrajeron los documentos con mayor relevancia para este trabajo, como son los que directamente hacen estimación de velocidad a partir de imágenes monoculares, hacen segmentación de vehículos o hacen segmentación de caminos. Estos tres campos se identificaron como los más importantes en consonancia con la propuesta de este documento y son los que se enuncian en la sección III.

III. VISIÓN DE MÁQUINA Y TÉCNICAS DE INTELIGENCIA ARTIFICIAL EN APLICACIONES DE TRÁNSITO

La visión de máquina es un campo en el que se estudian las distintas características y descriptores de las imágenes obtenidas mediante instrumentos de captura de imágenes (*e.g.* cámaras, espectrómetros, instrumentos de resonancia magnética, instrumentos de rayos X, *inter alia*).

Por su lado, la inteligencia artificial se dedica a hacer el uso de datos con el fin de tomar decisiones que pueden ser automatizadas y que pueden ser tomadas con la información disponible. De esta manera es posible hacer toma inteligente de decisiones con la información de los descriptores y características obtenidas aplicando visión de máquina.

Entre los procesos más comunes de visión de máquina con técnicas de inteligencia artificial se encuentra la detección, la clasificación y el rastreo de objetos, y la estimación de pose, ubicación y volumen de objetos.

En el caso específico de la aplicación de estas técnicas al tránsito se pueden encontrar ejemplos de detección de vehículos, detección de personas, detección de caminos, detección de marcas en los caminos, detección y clasificación de señales de tránsito, estimaciones de velocidad, detección de objetos en el camino que pueden representar peligro en la conducción, *inter alia*. Más adelante se muestran investigaciones en algunos estos temas.

Es importante tener en cuenta que para la aplicación de técnicas de visión de máquina la calidad de la cámara junto con otras características como su rango espectral y su ubicación son determinantes para el correcto análisis de las imágenes. En cuanto a la ubicación de las cámaras, y en específico para el caso de las aplicaciones de tránsito, se han clasificado los problemas en dos diferentes grupos:[10]

- 1) Escenas de tráfico estáticas: Las imágenes de este tipo de escenas se obtienen mediante el uso de cámaras

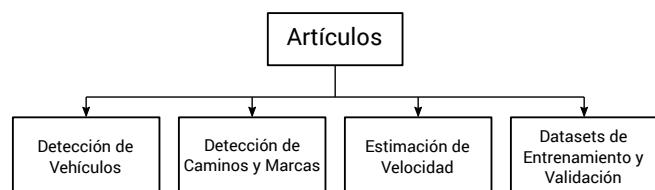


Figure 1: Clasificación de papers según su enfoque.

inmóviles, como cámaras de vigilancia domésticas y cámaras de tránsito.

- 2) Escenas de tráfico dinámicas: Las imágenes de este tipo de escenas se obtienen con cámaras móviles, como cámaras que se encuentran dentro, empotradas o embebidas en los vehículos e imágenes obtenidas con vehículos aéreos no tripulados UAVs (por su sigla en inglés Unmanned Aerial Vehicles) o robots.

Por otro lado, para este documento, se identificó la clasificación mostrada en la Fig. 1. Los artículos del grupo *Bibliografía_Anotada* son los que se tomaron como referencia para la creación de este documento.

A. Detección de Vehículos

En el campo de detección de vehículos se puede encontrar en la literatura diferentes métodos de obtención de características al igual que métodos de clasificación.

Un método usado para la detección de vehículos es usando las características de Haar, el cual utiliza las intensidades lumínicas de cada pixel para generar un modelo simple en una región. Tal es el método usado en [3] y [11], es justo notar que las dos fuentes proponen el uso de sus algoritmos en sistemas embebidos, esto es porque la obtención de las características de Haar suponen poco esfuerzo en términos de procesamiento. Sin embargo, [11] propone una segunda etapa de procesamiento de la información en la nube usando Redes Neuronales Convolucionales CNN (por su sigla en inglés Convolutional Neural Networks) con el fin de corroborar la información obtenida en la detección usando las características de Haar.

Hallar el par *background-foreground* también se ha convertido en un método ampliamente usado para la segmentación de vehículos, generalmente se busca el background y por consiguiente se obtienen los elementos en el foreground a los cuales se les obtendrían las características. Ejemplos de este tipo de técnica se encuentran en [12], [13], [14] y [15].

La obtención de los gradientes es importante como obtención de *features* necesarios para la detección de vehículos. Los gradientes dan información de bordes en las imágenes, que pueden ser usados para la segmentación de objetos. Este tipo de técnicas se pueden evidenciar en [16], [17] y [18].

Como en el caso de [11] es común encontrar el uso de redes neuronales (y sus variaciones) en la clasificación de la información referente a características de vehículos, tal es el caso de [19], [20] y [21]. Sin embargo, nótense que [21] no sólo se limita a la detección de vehículos usando Faster R-CNN, sino que adicionalmente usa esta técnica para encontrar peatones en la vía, especialmente niños (los cuales considera especialmente vulnerables en la vía y son detectados por el algoritmo seleccionando a peatones que miden menos de 1.5m de altura), con el fin de detectar infracciones de tráfico. En el caso de [20], la obtención de características se realizó usando filtros de Kalman, luego se procedió con el uso de redes neuronales para su clasificación.

Es posible utilizar mapas de saliencia como descriptores de vehículos. Para esto, el approach usado en [16] fue utilizar un detector de esquinas de Harris junto con los descriptores de mapas de saliencia para detectar vehículos.

Otros algoritmos para la detección y clasificación de vehículos usan características menos comunes. *Exempli gratia*, [22] usa un rectángulo envolvente para el vehículo y estima su volumen usando una línea que atraviesa el rectángulo, aunque este método no es robusto ante distintas poses del vehículo es importante incursionar en los distintos métodos de detección y evaluar su desempeño. Por su parte, [23] usa la información espectral de un vehículo previamente identificado para hacer posteriores identificaciones con distintos dispositivos de captura de imágenes, en el paper se muestra la correcta clasificación entre vehículos que pueden incluso tener características similares. Por otro lado, comparaciones entre algoritmos usando sets de tránsito también han sido presentadas. [26] evalúa el desempeño de YOLO, Retinanet y RCNN con los mismos conjuntos de datos, obteniendo como resultado que los mejores desempeños se obtuvieron de YOLOv3 y RCNN, balanceando el promedio de la media de la precisión y la cantidad de FPS de procesamiento. [27] compara los métodos de MoG-SVM con Faster RCNN, demostrando que el desempeño general de Faster RCNN es mejor que el de la combinación MoG-SVM.

Cabe notar que se encontró poco trabajo en el aspecto de visión tridimensional, el único caso identificado fue el de [28], en el cuál se utilizan *structure from motion* (SfM) para la detección de vehículos en una escena estática.

Un importante aporte se hace en [29], en el cuál se deja ver la posibilidad de la escasez de datos para análisis y se propone un método de aumentación basado en cambios morfológicos de la region de interés tales como rotaciones y escalas.

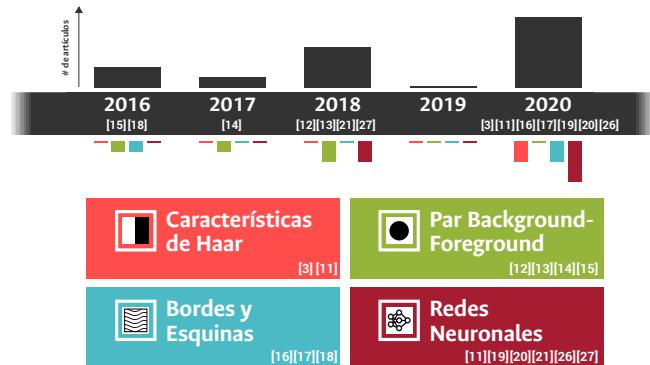


Figure 2: Línea de tiempo de artículos relacionados con las técnicas de detección de vehículos.

B. Detección de caminos y detección de marcas en los caminos

En el caso de la detección de los caminos es importante notar que todos tienen dependencia de la inversión de perspectiva, esto se puede evidenciar en [10], [31], [32], [33] y [34]. Sin embargo, en la aproximación a la segmentación y la clasificación de los vehículos; [10] usa el modelo Gaussiano de fondo y sombra (GBSM por sus siglas en inglés Gaussian Background Shadow Model), mientras que [31] utiliza PCA-HOG para la obtención de características y SVM para la clasificación. Uno de los métodos más importantes es el de [32] que permite estimar las aceleraciones angulares en los diferentes grados de libertad del vehículo, dado que su resultado es un mosaico del camino en el cual se puede ver claramente las curvas tomadas, esto sumado a un elemento de captura de velocidad permite calcular las aceleraciones dichas previamente. El uso de redes neuronales convolucionales también se puede evidenciar en el campo de la detección de caminos, esto se puede ver en [36], [37], [38] y [33]. El caso de [33] muestra una aproximación interesante al problema de la detección de los caminos, ya que usa PCA para calcular la cromática de la escena de tal forma que permite hacer eliminación de sombras. Posteriormente utiliza redes neuronales convolucionales para la segmentación del camino. [39] Tal como en el caso anterior, la visión tridimensional no fue mayormente identificada en la investigación, el único caso que se evidenció fue el de [37], en el que se hace un match entre la información tridimensional obtenida a partir de una radar y el mapa de colores obtenido a partir de una cámara monocular.

Entre otras técnicas se hace uso de cámaras térmicas para la identificación de caminos. [40] En este caso, las variaciones de temperatura del pavimento con respecto al de los demás elementos de la escena (especialmente las marcas de los caminos) permite obtener una segmentación efectiva del camino. Este approach, sin embargo, es susceptible a errores debidos a reflectividad de las marcas de los caminos.



Figure 3: Línea de tiempo de artículos relacionados con las técnicas de detección de caminos.

C. Estimación de velocidad

En el aspecto de la estimación de velocidad se encontraron dos modelos, en general se propone utilizar la sombra como el elemento de rastreo del vehículo ya que muestra el posicionamiento del vehículo con respecto al suelo, este es el caso de [41]. Mientras que [42] propone un acercamiento más analítico al problema, en este paper se ilustra la obtención de un modelo de densidad de probabilidad en el cambio de intensidad de los píxeles, el cual al compararse con modelos obtenidos previamente permiten hacer la correspondiente estimación.

Es común encontrar que el rastreo (tracking) de los objetos se ejecute a partir de detección de blob y la traza de su centroide, luego de tener el centroide y de ver su traza en los diferentes frames de una secuencia de imágenes, se puede estimar la velocidad del objeto. [12], [44]

En el caso específico de [44] (escena estática), se presenta un algoritmo en el cual se obtiene una imagen borrosa a partir de intercalar pares de imágenes usando sus filas de tal forma que una de las imágenes se identificaría como par y la otra como impar. La diferencia de los frames representa la extracción de background-foreground, un análisis por separado de los impares y los pares permite encontrar el centroide de los elementos y estimar su velocidad.

D. Datasets para entrenamiento y validación

Adicionalmente se han propuesto diferentes conjuntos de datos para hacer entrenamiento y validación de la información. [45] presenta una colección de datos de una calle en forma de T con cámara monocular RGB para escenas iluminadas y con cámara NIR para escenas de poca iluminación, en este se pueden observar vehículos con diferentes poses, escalas e iluminación. El trabajo de [46] muestra una colección de datos obtenida de obtener información de diversos sensores empotrados en un vehículo que fue transitado por diferentes zonas con diversas condiciones ambientales.

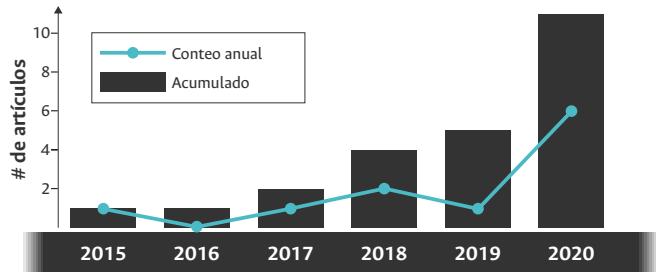


Figure 4: Línea de tiempo de artículos haciendo uso de redes neuronales para clasificación.

Adicionalmente a esto, se pudo identificar una base de datos en común usada por los diferentes artículos para hacer las pruebas en sus algoritmos, esta base de datos es conocida como *the KITTI dataset*. [47] Esta base de datos fue usada para probar el desempeño y robustez de los algoritmos presentados en [28], [36], [37], [38], [39] y [48]

IV. CONCLUSIONES Y DISCUSIÓN

Se identificaron similitudes en las diferentes áreas de trabajo, tal es el caso del uso constante de características basadas en gradientes o la extracción del background para la segmentación de vehículos. Por otro lado un común denominador es el uso de características morfológicas en blobs para la estimación de velocidad de esos vehículos.

En el caso de la segmentación de los caminos fue común ver el uso de la inversión de perspectiva para tener una vista birds-eye del camino y proceder a su correcta segmentación. Esto puede verse reflejado en la Fig. 3.

Es evidente el uso cada vez más generalizado de las redes neuronales para la detección, obtención de características y clasificación de objetos. Se evidenciaron múltiples casos durante el levantamiento de este estado del arte, tal y como lo muestra la Figura 4.

Fue muy notoria la falta de investigación en el campo de visión tridimensional, esto puede ser debido a la complejidad del procesamiento (en términos del tiempo de cómputo) de los algoritmos. Sin embargo se identificaron dos casos muy puntuales en los que se pretende detectar vehículos o bien segmentar caminos, tales son los casos de [28] y [37].

Es por esto último que se ha decidido realizar un algoritmo que permita hacer la estimación de velocidad de vehículos con visión tridimensional utilizando imágenes obtenidas de instrumentos de captura monoculares en escenas estáticas.

Los retos importantes mejor identificados tienen que ver con la invarianza a la iluminación en la detección o clasificación de cualquier tipo de escena, en el caso de la clasificación de los vehículos. Por el lado de la segmentación de caminos, un reto importante parece ser el manejo de la segmentación utilizando imágenes a las cuales no se les es posible hacer una inversión de perspectiva, como en curvas.

REFERENCIAS

- [1] *Siniestros en las vías, un problema de salud pública*, El Tiempo, Feb. 2018. [Online]. Available: <https://www.eltiempo.com/salud/informe-de-la-oms-sobre-accidentes-de-transito-en-el-mundo-302888> (visited on 05/01/2020).
- [2] *Road safety: Vision zero on the move*, Swedish Transport Administration, 2012.
- [3] F. M. Javed Mehedi Shamrat, I. Mahmud, A. Rahman, A. Majumder, Z. Tasnim, and N. I. Nobel, “A smart automated system model for vehicles detection to maintain traffic by image processing”, *International Journal of Scientific and Technology Research*, vol. 9, no. 2, pp. 2921–2928, 2020. [Online]. Available: <http://www.ijstr.org/final-print/feb2020/A-Smart-Automated-System-Model-For-Vehicles-Detection-To-Maintain-Traffic-By-Image-Processing.pdf>.
- [4] *Vision zero*, Wikipedia - The Free Encyclopedia, Apr. 2020. [Online]. Available: https://en.wikipedia.org/wiki/Vision_Zero (visited on 05/06/2020).
- [5] S. A. Elsagheer Mohamed, “Automatic Traffic Violation Recording and Reporting System to Limit Traffic Accidents: Based on Vehicular Ad-hoc Networks (VANET)”, in *Proceedings of 2019 International Conference on Innovative Trends in Computer Engineering, ITCE 2019*, Computer Engineering Department, College of Computer, Qassim University, P.O.B 6688, Buryadah, 51453, Saudi Arabia: IEEE, 2019, pp. 254–259, ISBN: 9781538652602. DOI: 10.1109/ITCE.2019.8646449. [Online]. Available: <https://ieeexplore.ieee.org/document/8646449>.
- [6] *Cámaras salvavidas*, Secretaría Distrital de Movilidad, 2019. [Online]. Available: <https://www.camarassalvavidasbogota.com/> (visited on 05/06/2020).
- [7] U.S. Department of Transportation, Federal Highway Administration, “SPEED Enforcement, CAMERA SYSTEMS, Operational Guidelines”, eng, Apr. 2008. [Online]. Available: https://safety.fhwa.dot.gov/speedmgt/ref_mats/fhwasa09028/5.htm.
- [8] C. Wilson, C. Willis, J. K. Hendrikz, R. Le Brocq, and N. Bellamy, “Speed cameras for the prevention of road traffic injuries and deaths”, eng, *Cochrane Database of Systematic Reviews*, no. 10, p. CD004607, Oct. 2010, ISSN: 1469493X. DOI: 10.1002/14651858.cd004607.pub4. [Online]. Available: <https://pubmed.ncbi.nlm.nih.gov/20927736>.
- [9] Department of Justice and Community Safety, *How do we know red-light and speed cameras work?*, YouTube, Apr. 2011. [Online]. Available: <https://www.youtube.com/watch?v=Vz5pMBLHyMI> (visited on 05/26/2020).
- [10] C.-Y. Fang, H.-P. Chou, J.-M. Wang, and S.-W. Chen, “Automatic road segmentation of traffic images”, in *VISAPP 2015 - 10th International Conference on Computer Vision Theory and Applications; VISIGRAPP, Proceedings*, vol. 2, Dept. of Computer Science and Information Engineering, National Taiwan Normal University, Taipei City, Taiwan, 2015, pp. 469–477. [Online]. Available: <https://www.scitepress.org/Link.aspx?doi=10.5220/0005321904690477>.
- [11] W. Alasmary, “An innovative smartphone-based solution for traffic rule violation detection”, *International Journal of Advanced Computer Science and Applications*, vol. 11, no. 1, pp. 625–636, 2020. [Online]. Available: <https://thesai.org/Publications/ViewPaper?Volume=11&Issue=1&Code=IJACSA&SerialNo=77>.
- [12] R. M. Waregaonkar, S. M. Deokar, S. S. Patankar, and J. V. Kulkarni, “Development of prototype for vehicle speed measurement”, in *RTEICT 2017 - 2nd IEEE International Conference on Recent Trends in Electronics, Information and Communication Technology, Proceedings*, vol. 2018-Janua, Vishwakarma Institute of Technology, Pune, India, 2017, pp. 945–949. DOI: 10.1109/RTEICT.2017.8256737. [Online]. Available: <https://ieeexplore.ieee.org/document/8256737>.
- [13] K. Sharma, “Feature-based efficient vehicle tracking for a traffic surveillance system”, *Computers and Electrical Engineering*, vol. 70, pp. 690–701, 2018, ISSN: 00457906. DOI: 10.1016/j.compeleceng.2017.10.002. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S004579061730215X>.
- [14] R. K. C. Billones, A. A. Bandala, E. Sybingco, L. A. G. Lim, and E. P. Dadios, “Intelligent system architecture for a vision-based contactless apprehension of traffic violations”, in *IEEE Region 10 Annual International Conference, Proceedings/TENCON*, De la Salie University, Manila, Philippines, 2017, pp. 1871–1874, ISBN: 9781509025978. DOI: 10.1109/TENCON.2016.7848346. [Online]. Available: <https://ieeexplore.ieee.org/document/7848346>.
- [15] M. Nabila, B. J. Yousra, and E. Watelain, “Optimized HOG descriptor for on road cars detection”, in *ACM International Conference Proceeding Series*, vol. 12-15-Sept, National School of Engineers-Tunisia, ReD-CAD Laboratory, Valenciennes University-France, LAMIH Laboratory, France, 2016, pp. 166–171. DOI: 10.1145/2967413.2967415. [Online]. Available: <https://dl.acm.org/doi/10.1145/2967413.2967415>.
- [16] M. S. Aktar and Y. Horita, “Performance analysis of vehicle detection based on spatial saliency and local image features in H.265 (HEVC) 4K video for developing a relationship between iou and subjective evaluation value”, *IEEJ Transactions on Electrical and*

- Electronic Engineering*, vol. 15, no. 4, pp. 563–569, 2020. DOI: 10.1002/tee.23089. [Online]. Available: <https://onlinelibrary.wiley.com/doi/full/10.1002/tee.23089>.
- [17] A. ŞentAŞ, İ. Tashiev, F. Küçükayvaz, S. Kul, S. Eken, A. Sayar, and Y. Becerikli, “Performance evaluation of support vector machine and convolutional neural network algorithms in real-time vehicle type and color classification”, *Evolutionary Intelligence*, vol. 13, no. 1, pp. 83–91, 2020. DOI: 10.1007/s12065-018-0167-z. [Online]. Available: <https://link.springer.com/article/10.1007/s12065-018-0167-z>.
- [18] Z. Czapla, *Orthogonal gradient-based binary image representation for vehicle detection*, Faculty of Transport, Silesian University of Technology, ul. Krasinskiego 8, Katowice, 40-019, Poland, 2016. DOI: 10.1007/978-3-319-46418-3_40. [Online]. Available: <https://link.springer.com/article/10.1007%2Fs12065-018-0167-z>.
- [19] C. Valliyammai, J. Sridharan, and A. Ramanathan, *Automation of Traffic Violation Detection and Penalization*, Department of Computer Technology, Madras Institute of Technology Campus, Anna University, Chennai, Tamil Nadu, India, 2020. DOI: 10.1007/978-981-15-1483-8_21. [Online]. Available: https://link.springer.com/chapter/10.1007%2F978-981-15-1483-8_21.
- [20] A. Tuama, H. Abdulrahman, and B. Magnier, “Integrated convolutional neural network model with statistical moments layer for vehicle classification”, in *Proceedings of SPIE - The International Society for Optical Engineering*, vol. 11433, Computer Engineering Department, Northern Technical University, Kirkuk, Iraq, 2020. DOI: 10.1117/12.2559375. [Online]. Available: <https://www.spiedigitallibrary.org/conference-proceedings-of-spie/11433/2559375/Integrated-convolutional-neural-network-model-with-statistical-moments-layer-for/10.1117/12.2559375.short>.
- [21] J. Spanhel, J. Sochor, and A. Makarov, “Detection of Traffic Violations of Road Users Based on Convolutional Neural Networks”, in *2018 14th Symposium on Neural Networks and Applications, NEUREL 2018*, Faculty of Information Technology, Brno University of Technology, Czech Republic, 2018. DOI: 10.1109/NEUREL.2018.8586996. [Online]. Available: <https://ieeexplore.ieee.org/document/8586996>.
- [22] G. Zhang and Y. Wang, “Chapter 3 - Machine Learning and Computer Vision-Enabled Traffic Sensing Data Analysis and Quality Enhancement”, in, Y. Wang and Z. B. T. - D.-D. S. t. T. P. Zeng, Eds., Elsevier, 2019, pp. 51–79, ISBN: 978-0-12-817026-7. DOI: 10.1016/B978-0-12-817026-7.00003-5.
- [23] X.-Q. Zhu, Z.-J. Li, W.-H. Zhao, J.-Y. Li, H.-W. Liang, X.-Y. Li, Z.-G. Cai, and J.-H. Wang, “A selectable imaging spectrum vehicle recognition method based on spectral feature”, in *Proceedings of SPIE - The International Society for Optical Engineering*, vol. 11427, State Key Laboratory of Optoelectronic Materials and Technology, School of Physics, Sun Yat-sen University, Guangzhou, Guangdong, China, 2020. DOI: 10.1117/12.2551434. [Online]. Available: <https://www.spiedigitallibrary.org/conference-proceedings-of-spie/11427/2551434/A-selectable-imaging-spectrum-vehicle-recognition-method-based-on-spectral/10.1117/12.2551434.short>.
- [24] S. G. Da Silva Filho, R. Z. Freire, and L. Dos Santos Coelho, “Feature extraction for on-road vehicle detection based on support vector machine”, in *ESANN 2017 - Proceedings, 25th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*, Pontifical Catholic University of Parana, PUCPR Polytechnic School Imaculada Conceição, 1155 - Postal Code, Curitiba, PR, 80215-901, Brazil, 2017, pp. 65–70. [Online]. Available: <https://www.elen.ucl.ac.be/Proceedings/esann/esannpdf/es2017-112.pdf>.
- [25] R. Y. Wankhede and D. R. Marur, *Enhanced vehicle detection and tracking system for nighttime*, Embedded System Technology, Electronics and Communication Engineering, SRM University, Chennai, 603203, India, 2017. DOI: 10.1007/978-981-10-3174-8_55. [Online]. Available: https://link.springer.com/chapter/10.1007%2F978-981-10-3174-8_55.
- [26] M. Bugeja, A. Dingli, M. Attard, and D. Seychell, “Comparison of Vehicle Detection Techniques applied to IP Camera Video Feeds for use in Intelligent Transport Systems”, *Transportation Research Procedia*, vol. 45, pp. 971–978, 2020, ISSN: 2352-1465. DOI: 10.1016/j.trpro.2020.02.069. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S2352146520301198>.
- [27] A. Arinaldi, J. A. Pradana, and A. A. Gurusinga, “Detection and classification of vehicles for traffic video analytics”, *Procedia Computer Science*, vol. 144, pp. 259–268, 2018, ISSN: 1877-0509. DOI: 10.1016/j.procs.2018.10.527. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1877050918322361>.
- [28] F. Chhaya, D. Reddy, S. Upadhyay, V. Chari, M. Z. Zia, and K. M. Krishna, “Monocular reconstruction of vehicles: Combining SLAM with shape priors”, in *Proceedings - IEEE International Conference on Robotics and Automation*, vol. 2016-June, Interna-

- tional Institute of Information Technology, Hyderabad, India, 2016, pp. 5758–5765. DOI: 10.1109/ICRA.2016.7487799. [Online]. Available: <https://ieeexplore.ieee.org/document/7487799/>.
- [29] R. K. C. Billones, A. A. Bandala, L. A. Gan Lim, E. Sybingco, A. M. Fillone, and E. P. Dadios, *Pedestrian-Motorcycle Binary Classification Using Data Augmentation and Convolutional Neural Networks*, De La Salle University, Manila, Philippines, 2019. DOI: 10.1007/978-3-030-22871-2_50. [Online]. Available: https://link.springer.com/chapter/10.1007%2F978-3-030-22871-2_50.
- [30] J. J. Anaya, A. Ponz, F. García, and E. Talavera, “Motorcycle detection for ADAS through camera and V2V Communication, a comparative analysis of two modern technologies”, *Expert Systems with Applications*, vol. 77, pp. 148–159, 2017, ISSN: 0957-4174. DOI: 10.1016/j.eswa.2017.01.032. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0957417417300416>.
- [31] L. Ding, H. Zhang, J. Xiao, B. Li, S. Lu, R. Klette, M. Norouzifard, and F. Xu, “A comprehensive approach for road marking detection and recognition”, *Multimedia Tools and Applications*, 2020, ISSN: 15737721. DOI: 10.1007/s11042-019-08384-5. [Online]. Available: <https://link.springer.com/article/10.1007%2Fs11042-019-08384-5>.
- [32] W. Li and Y. Cao, “A Rapid Road Image Mosaic Method Based on Monocular Camera”, in *Journal of Physics: Conference Series*, vol. 1437, School of Mathematics, Physics, Qingdao University of Science, and Technology, No. 99 Songling Road, Qingdao, Shandong, China, 2020. DOI: 10.1088/1742-6596/1437/1/012008. [Online]. Available: <https://iopscience.iop.org/article/10.1088/1742-6596/1437/1/012008>.
- [33] T. Kim, Y.-W. Tai, and S.-E. Yoon, “PCA based computation of illumination-invariant space for road detection”, in *Proceedings - 2017 IEEE Winter Conference on Applications of Computer Vision, WACV 2017*, KAIST, South Korea, 2017, pp. 632–640. DOI: 10.1109/WACV.2017.76. [Online]. Available: <https://ieeexplore.ieee.org/document/7926659/>.
- [34] X. Liu, Z. Cheng, and F. Yi, “A road detection technology based on reverse perspective transformation”, in *Proceedings - 2016 8th International Conference on Intelligent Human-Machine Systems and Cybernetics, IHMSC 2016*, vol. 1, ShanDongJiaoTong University, JiNan, China, 2016, pp. 126–129, ISBN: 9781509007684. DOI: 10.1109/IHMSC.2016.24. [Online]. Available: <https://ieeexplore.ieee.org/document/7783575/>.
- [35] J. Xiao, W. Xiong, Y. Yao, L. Li, and R. Klette, “Lane detection algorithm based on road structure and extended Kalman filter”, *International Journal of Digital Crime and Forensics*, vol. 12, no. 2, pp. 1–20, 2020. DOI: 10.4018/IJDCF.2020040101. [Online]. Available: <https://www.igi-global.com/gateway/article/246835>.
- [36] C.-A. Brust, S. Sickert, M. Simon, E. Rodner, and J. Denzler, “Convolutional patch networks with spatial prior for road detection and urban scene understanding”, in *VISAPP 2015 - 10th International Conference on Computer Vision Theory and Applications; VISIGRAPP, Proceedings*, vol. 2, Computer Vision Group, Friedrich Schiller University of Jena, Jena, Germany, 2015, pp. 510–517. [Online]. Available: <https://www.scitepress.org/Link.aspx?doi=10.5220/0005355105100517>.
- [37] L. Deng, M. Yang, Z. Liang, Y. He, and C. Wang, “Fusing geometrical and visual information via superpoints for the semantic segmentation of 3D road scenes”, *Tsinghua Science and Technology*, vol. 25, no. 4, pp. 498–507, 2020. DOI: 10.26599/TST.2019.9010038. [Online]. Available: <https://ieeexplore.ieee.org/document/8954868>.
- [38] M. Ochman, “Hybrid approach to road detection in front of the vehicle”, *IFAC-PapersOnLine*, vol. 52, no. 8, pp. 393–396, 2019, ISSN: 24058963. DOI: 10.1016/j.ifacol.2019.08.078. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S2405896319304112>.
- [39] M. Junaid, M. Ghafoor, A. Hassan, S. Khalid, S. A. Tariq, G. Ahmed, and T. Zia, “Multi-feature view-based shallow convolutional neural network for road segmentation”, *IEEE Access*, vol. 8, pp. 36612–36623, 2020. DOI: 10.1109/ACCESS.2020.2968965. [Online]. Available: <https://ieeexplore.ieee.org/document/8988193/>.
- [40] B.-C. Yeo, W.-S. Lim, and H.-S. Lim, “Lane detection in the absence of lane markings for roadway surveillance with thermal vision”, *International Journal of Innovative Computing, Information and Control*, vol. 12, no. 3, pp. 677–688, 2016. [Online]. Available: <http://www.ijicic.org/ijicic-120301.pdf>.
- [41] S. Lu, Y. Wang, and H. Song, “A high accurate vehicle speed estimation method”, *Soft Computing*, vol. 24, no. 2, pp. 1283–1291, 2020, ISSN: 14337479. DOI: 10.1007/s00500-019-03965-w. [Online]. Available: <https://link.springer.com/article/10.1007%2Fs00500-019-03965-w>.
- [42] M. Dahl and S. Javadi, “Analytical modeling for a video-based vehicle speed measurement framework”, *Sensors (Switzerland)*, vol. 20, no. 1, pp. 1–10, 2020, ISSN: 14248220. DOI: 10.3390/s20010160. [Online].

- Available: <https://www.mdpi.com/1424-8220/20/1/160>.
- [43] G. Jati, A. A. S. Gunawan, and W. Jatmiko, “Dynamic swarm particle for fast motion vehicle tracking”, *ETRI Journal*, vol. 42, no. 1, pp. 54–66, 2020. DOI: 10.4218/etrij.2018-0435. [Online]. Available: <https://onlinelibrary.wiley.com/doi/full/10.4218/etrij.2018-0435>.
- [44] Z. Peng, “Precise speed measurement using an interlaced scan image”, *Optics & Laser Technology*, vol. 43, no. 1, pp. 204–207, 2011, ISSN: 0030-3992. DOI: 10.1016/j.optlastec.2010.06.013. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0030399210001581>.
- [45] H. S. Bharadwaj, S. Biswas, and K. R. Ramakrishnan, “A large scale dataset for classification of vehicles in urban traffic scenes”, in *ACM International Conference Proceeding Series*, Department of Electrical Engineering, Indian Institute of Science, India, 2016.
- DOI: 10.1145/3009977.3010040. [Online]. Available: <https://dl.acm.org/doi/10.1145/3009977.3010040>.
- [46] Y. Weber and S. Kanarachos, “CUPAC – The Coventry University public road dataset for automated cars”, *Data in Brief*, vol. 28, p. 104950, 2020, ISSN: 2352-3409. DOI: 10.1016/j.dib.2019.104950. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S2352340919313058>.
- [47] A. Geiger, P. Lenz, and R. Urtasun, “Are we ready for autonomous driving? the kitti vision benchmark suite”, in *Conference on Computer Vision and Pattern Recognition (CVPR)*, 2012.
- [48] D. A. Chakra and J. Zelek, “Road segmentation in street view images using texture information”, in *Proceedings - 2016 13th Conference on Computer and Robot Vision, CRV 2016*, University of Waterloo, Waterloo, Canada, 2016, pp. 424–431. DOI: 10.1109/CRV.2016.47. [Online]. Available: <https://ieeexplore.ieee.org/document/7801553/>.