

Propuesta de control de acceso vehicular empleando aprendizaje profundo

Fernando Contreras-Pérez, Oscar Chávez-Bosquez,
José Hernández-Torruco, Betania Hernández-Ocaña

Universidad Juárez Autónoma de Tabasco,
División Académica de Ciencias y Tecnologías de la Información,
México

212H13001@alumno.ujat.mx,
{oscar.chavez,jose.hernandezt,betania.hernandez}@ujat.mx

Resumen. La vigilancia y el control de acceso en instituciones públicas o privadas son elementos muy importantes para contribuir a la seguridad de las personas, vehículos e inmuebles que se encuentren dentro del área o lugar custodiado. Si tomamos en cuenta que la inseguridad es uno de los problemas que más afectan al país y que en el estado de Tabasco se ha presentado una tendencia a la alza en los robos y hurtos a instituciones educativas durante los últimos años, entonces tiene sentido contribuir en un sistema que apoye a la vigilancia. Este trabajo propone un sistema de identificación automática de vehículos empleando aprendizaje profundo y reconocimiento óptico de caracteres para identificar y reconocer los caracteres de las matrículas de vehículos. El sistema propuesto cumple ser simple en su implementación y sus elementos son económicos, con el propósito de ser un modelo replicable para diferentes áreas o lugares de interés.

Palabras clave: Redes neuronales convolucionales, raspberry pi, openCV AI kit.

Proposal for Vehicle Access Control Using Deep Learning

Abstract. Abstract. Surveillance and access control in public or private institutions are key elements to ensuring the security of people, vehicles, and facilities within a monitored area. Considering that insecurity is one of the most pressing problems in the country, and that in the state of Tabasco there has been an upward trend in thefts and burglaries in educational institutions in recent years, it makes sense to contribute to a system that supports surveillance efforts. This work proposes an automatic vehicle identification system using deep learning and optical character recognition (OCR) to detect and recognize the characters on vehicle license plates. The proposed system is designed to be simple to implement and composed of cost-effective components, with the goal of being a replicable model for different areas or locations of interest.

Keywords: Convolutional neural networks, raspberry pi, openCV AI kit.

1. Introducción

La inseguridad es un problema social muy presente en México. Todos los días se cometen robos, asaltos, hurtos, secuestros, entre otros delitos. Este problema ha causado una serie de efectos en la sociedad. Según [28], existen cambios en las costumbres para salir de casa, para transportarse y pasear, lo cual desincentiva o limita las actividades sociales y políticas.

La inseguridad en el sector educativo no es la excepción. De acuerdo a los datos de las fiscalías estatales y las secretarías de Educación, entre marzo de 2020 y marzo de 2021 las escuelas de México han sufrido casi 7000 robos [18]. Por su parte, la Secretaría de Educación del estado de Tabasco (SETAB) reportó en 2021 que se habían registrado un total de 32 robos a escuelas públicas, el número más alto en los últimos cuatro años [6].

Con respecto al robo de autos particulares, en [21] se menciona que este delito tuvo un crecimiento del 40 % de 2015 a 2016 en Tabasco, pasando de 2250 a 3508 casos. De estos 3508 robos, el 75 % se registraron en la región Centro-Chontalpa. Justamente en esta región se ubica el Campus Chontalpa de la Universidad Juárez Autónoma de Tabasco (UJAT). Además, se sabe que el robo de autos es una actividad central en la economía criminal y tiene una relación íntima con otros delitos como el secuestro.

Por otro lado, durante muchos años la construcción de un sistema de reconocimiento de características requería de una cuidadosa ingeniería y vasta experiencia en el área para poder transformar los datos de su forma a cruda a una representación adecuada para los sistemas de aprendizaje automático. En cambio, los métodos de aprendizaje profundo son métodos de aprendizaje con múltiples niveles de representación. Esta representación se va transformando por niveles, desde la forma cruda de los datos hacia niveles superiores cada vez más abstractos. Además, las capas de características significativas se van aprendiendo de manera automática sin necesidad de ser diseñadas por ingenieros humanos. Este enfoque es muy útil, especialmente para descubrir características complicadas o confusas en datos de gran dimensión y ha batido récords en diferentes campos de la inteligencia artificial [14].

El aprendizaje profundo se basa en redes neuronales artificiales, las cuales poseen por naturaleza una capacidad de aprendizaje. De acuerdo a [4], los términos aprendizaje profundo y red neuronal profunda se refieren a una red neuronal artificial con múltiples capas. Además también menciona que el aprendizaje profundo es considerado una de las herramientas más poderosas y populares en la literatura gracias a su capacidad de manejar grandes volúmenes de datos. El interés en tener capas ocultas más profundas está empezando a superar el rendimiento de los métodos clásicos, especialmente en el campo del reconocimiento de patrones.

Debido a lo anterior, en este artículo se propone un sistema de identificación automática de vehículos en tiempo real empleando aprendizaje profundo que busca mejorar y agilizar la entrada de vehículos al Campus Chontalpa de la UJAT. Otro de los objetivos del sistema es el de contribuir a la seguridad de los vehículos, del personal de la universidad, estudiantes, trabajadores y comerciantes, y de las instalaciones en general. Esto mediante la clasificación e identificación automática de los vehículos de profesores, estudiantes, y en general, de los vehículos que ingresen al campus.

2. Trabajos relacionados

Existen muchas formas de identificar vehículos de manera automática, ya sea empleando técnicas de inteligencia artificial o técnicas de otras áreas de las Ciencias de la Computación [3]. Dentro del estado del arte de la identificación automática de vehículos, se han utilizado principalmente tres enfoques: uso de sensores, uso de algoritmos clásicos de visión computacional y uso de aprendizaje profundo.

Con respecto al uso de sensores, en [9,8] utilizaron redes de sensores con etiquetas de identificación de radio frecuencia (RFID, del inglés *Radio-Frequency Identification*) y el protocolo de largo alcance (LoRa, del inglés *Long Range*) para la identificación de vehículos y la comunicación con un servidor en la nube. Además, propusieron una arquitectura para una red de sensores que aborda el problema de monitorear las redes de tráfico. Las principales desventajas de esta propuesta es la adquisición de dispositivos y la integración de diferentes tecnologías. Además, el tiempo de vida útil de un sensor se ve afectado por diversos factores como sobrecalentamiento, humedad, desperfecto por vibraciones, entre otras.

En cuanto a las técnicas clásicas de visión computacional destacan [30,26,2], en los cuales utilizan el algoritmo HOG (*Histogram of oriented gradients*) para describir propiedades representativas del vehículo, como la apariencia general y la textura local. También se propone un sistema de identificación de vehículos que tome en cuenta no solo la forma del vehículo, sino también su matrícula. Por otro lado, también se abordó el problema del monitoreo de las actividades en las intersecciones de tráfico para detectar congestiones y luego predecir el flujo de vehículos, lo que ayuda a regular el tráfico.

Finalmente, existe la tendencia de emplear aprendizaje profundo para la identificación automática de vehículos. En ese sentido, en [23] se aborda este problema mediante un sistema dividido en tres partes: detección, segmentación y reconocimiento de caracteres. La parte de detección de los vehículos puede ser realizada mediante un modelo de red neuronal existente, modificado o propio. En [12,10,25,29] se utilizan diferentes versiones y modificaciones que mejoran uno de los modelos de red neuronal más utilizados para la detección de vehículos: YOLO [22] (del inglés *You Only Look Once*). También se utilizan herramientas tecnológicas como Raspberry Pi3 y módulos de cámara Pi NoIR [12]. Algunos trabajos como [17,24] utilizan la identificación de vehículos con objetivos más

específicos como el monitoreo de las reglas de tránsito, la vigilancia del robo de vehículos o la estimación dinámica de flujos origen-destino. En estos trabajos se toman en cuenta distintos aspectos y detalles clave tales como imágenes en color y escala de grises, la calidad de las imágenes, la velocidad de movimiento de los vehículos, la iluminación, las condiciones climáticas, las variaciones en ángulos, entre otros. Además se presta atención a las características de la placa que varían según el estado o país de origen tales como colores, tamaños, tipos de alfabeto, diseño de los dígitos y caracteres escasos.

Un trabajo muy importante dentro del estado del arte es [27]. En éste se realiza una revisión de las principales arquitecturas de aprendizaje profundo utilizadas en la detección de vehículos, destacando principalmente RetinaNet [15], gracias a su precisión de detección bastante alta, que a su vez, es consecuencia de una función de pérdida que puede reducir efectivamente el peso de las muestras fáciles de clasificar y así centrarse en las muestras difíciles en la fase de entrenamiento.

Además por medio de experimentos comparativos, se encuentra que el valor de la métrica *recall* de SSD [16] (del inglés *Single Shot MultiBox Detector*) es bajo, y hay una gran tasa de detección errónea. Por su parte, YOLOv3 se comporta de manera contraria, con un valor de *recall* más alto y un valor de *precision* más bajo.

Por otro lado, en las pruebas realizadas en escenarios reales, se descubre que SSD también posee una excelente capacidad de generalización ya que la construcción del modelo es menos propensa al sobreajuste y cumple ser robusto.

3. Descripción del problema

El Campus Chontalpa de la UJAT se encuentra ubicado en el municipio de Cunduacán en el estado de Tabasco. Este campus alberga tres divisiones académicas de la Universidad: la División Académica de Ciencias Básicas, la División Académica de Ciencias y Tecnologías de la Información y la División Académica de Ingeniería y Arquitectura.

Las instalaciones del campus cuentan con varios edificios de diferentes tipos, entre ellos: aulas de clases, oficinas administrativas, cubículos para profesores, centros de investigación, laboratorios, centros de cómputo, una biblioteca, salas audiovisuales, papelerías, entre otros. Además de estos edificios, que normalmente son de uso exclusivo de alumnos, profesores y trabajadores, el campus también cuenta con instalaciones de negocios y áreas comunes como un Centro de lenguas extranjeras abierto al público en general, auditorios, una cancha de pasto sintético, canchas de baloncesto, una cancha de fútbol rápido, y un campo de fútbol. También se encuentra ubicado dentro del campus el Centro de Investigación de Ciencia y Tecnología Aplicada de Tabasco (CICTAT). Debido a lo anterior, y al hecho de que a menudo se realizan eventos de distinta índole dentro del campus, actualmente se requiere una mayor atención y control sobre el acceso de los vehículos.



Fig. 1. Vista satelital del acceso al campus.

La cantidad de alumnos que asisten al Campus Chontalpa es de aproximadamente 8000 entre las diferentes licenciaturas y posgrados de las tres Divisiones Académicas. La cantidad de profesores e investigadores es de aproximadamente 600, además de los trabajadores de vigilancia, intendencia y de los comercios dentro del campus es de aproximadamente 500. No es una tarea simple la identificación de esta cantidad de vehículos por solo 2 o 3 personas encargadas de la vigilancia del portón de acceso al campus. Una persona podría recordar el color y probablemente hasta el modelo de un conjunto de vehículos, pero difícilmente recordará las matrículas.

Es importante mencionar que para el acceso y salida de vehículos del Campus Chontalpa de la UJAT se tiene un solo punto, el cual cuenta con un puesto de control y vigilancia (Figura 1). En este punto de acceso siempre se mantiene al menos un trabajador de vigilancia, esto con el fin de llevar el control de los vehículos que ingresan al campus. Por otra parte, el hecho de que exista solamente una entrada, genera como resultado una fila de vehículos que esperan pasar por el control del empleado de vigilancia. Esto representa un problema que empeora durante las horas pico, las cuales representan los horarios en que el número de ingresos de vehículos es significativamente mayor al resto del día. En las horas más concurridas, la fila de vehículos que se forma en la entrada del campus llega a invadir la carretera (ver Figura 2). Esta invasión y obstrucción ocasiona que el tránsito del municipio también se vea afectado, además de aumentar el riesgo de accidentes entre los automovilistas.

Debido a lo anterior, la implementación de un sistema de control de acceso vehicular es factible, ya que bastará con tener un solo dispositivo de acceso en este punto para monitorear la entrada y salida de los vehículos.

4. Materiales y método

4.1. Materiales

Para el desarrollo de nuestra propuesta se requiere el siguiente equipo de hardware y software:



Fig. 2. Control de acceso para ingresar al Campus Chontalpa de la UJAT.

Sensor OAK Lite. El kit OpenCV de inteligencia artificial con profundidad¹ (OAK-D, del inglés *OpenCV Artificial Intelligence Kit with Depth*) cuenta con tres cámaras integradas que implementan la visión estereoscópica y RGB, que a su vez están acopladas a un procesador Intel llamado Myriad X VPU (del inglés *Vision Processing Unit*) capaz de ejecutar modelos de aprendizaje profundo.

Mobilenet SSDv2. Este modelo de red neuronal convolucional, al igual que la mayoría de los modelos de redes ligeras, utiliza Mobilenet-v2 como red troncal. Esta incluye una capa convolucional estándar y 17 módulos residuales inversos. Por su parte, cada módulo residual inverso contiene una capa convolucional 1x1, una capa convolucional separable *Dwise* 3x3, funciones de normalización por lotes (BN, del inglés *Batch Normalization*) y función de activación *Relu6*.

TensorFlow Object Detection API. Es una biblioteca de código abierto para cálculo numérico y que usa como forma de programación grafos de flujo de datos. El código fue liberado como software libre e incluyó mejoras, como potenciar el rendimiento gracias al uso de unidades de procesamiento gráfico (GPU, del inglés *Graphics Processing Unit*) [1]. Además, TensorFlow facilita y acelera la investigación y la aplicación de modelos de redes neuronales y otros modelos de aprendizaje automático. La TensorFlow Object Detection API sirve para entrenar las últimas capas de una red neuronal convolucional (CNN, del inglés *Convolutional Neural Network*) con capas personalizadas. Además, facilita la construcción, el entrenamiento y el despliegue de modelos de detección de objetos [11].

PaddleOCR versión 2.6.0. Es un conjunto de herramientas de reconocimiento óptico de caracteres (OCR, del inglés *Optical Character*

¹ <https://docs.luxonis.com/projects/hardware/en/latest/pages/DM9095.html>

Recognition) multilingüe basadas en el framework PaddlePaddle² (del inglés *PA*rallel *D*istributed *D*eep *L*Earning) que admite el reconocimiento de combinaciones de caracteres en diferentes idiomas de forma vertical u horizontal [31]. El objetivo de PaddleOCR es crear herramientas de OCR multilingües y prácticas que ayuden a los usuarios a entrenar mejores modelos y aplicarlos en la práctica.

Raspberry Pi 3 modelo B. Computadora de placa reducida o placa única (SBC – *SingleBoard Computer*) de bajo costo [5]. Utiliza un microprocesador con arquitectura ARM, memoria RAM y tarjeta gráfica (GPU) en un solo chip, por tanto se trata de un sistema SoC (*System on a Chip*, Sistema en un chip). La Raspberry Pi 3 Modelo B es el primer modelo de la tercera generación de Raspberry Pi. Sustituyó a la Raspberry Pi 2 Model B en febrero de 2016.

OpenVINO. El (*Open Visual Inferencing and Neural Network Optimization*)³ de Intel, es un kit de herramientas para desarrollar aplicaciones y soluciones basadas en el aprendizaje profundo. Entre estas tareas se encuentra la simulación de la visión humana, y el reconocimiento automático del habla. Además, proporciona un alto rendimiento y diversas opciones de implementación, desde cómputo en dispositivos integrados hasta cómputo en la nube.

4.2. Método

Para que el sensor identifique matrículas de vehículos en tiempo real y reconozca de qué vehículo se trata, planteamos la siguiente metodología:

- Recopilar un conjunto de imágenes de entrenamiento. Como primer paso usaremos el dataset de uso libre “Open Images Dataset V6”⁴, el cual contiene una gran cantidad de matrículas de vehículos ya etiquetadas.
- *Data augmentation*. Aplicaremos transformaciones a cada imagen para exponer al modelo a variaciones de matrículas para así volverlo más robusto.
- *Transfer learning*. Entrenar las últimas capas de Mobilenet SSDv2 con nuestro conjunto de datos y así obtener el modelo final que reconozca matrículas de vehículos locales.
- Validación del modelo. Además de monitorear el desempeño con métricas de validación durante el entrenamiento, probaremos el modelo con imágenes de vehículos y matrículas desconocidas. Con base en estas pruebas, se calcularán las métricas *precision* y *recall*.
- *Deployment* en el dispositivo OAK Lite. Exportar el modelo de TensorFlow a DepthAI empleando la plataforma OpenVINO.

² <https://github.com/PaddlePaddle/PaddleOCR>

³ https://docs.openvino.ai/latest/openvino_docs_install_guides_overview.html

⁴ https://storage.googleapis.com/openimages/web/visualizer/index.html?set=train&type=segmentation&r=false&c=%2Fm%2F01jfm_

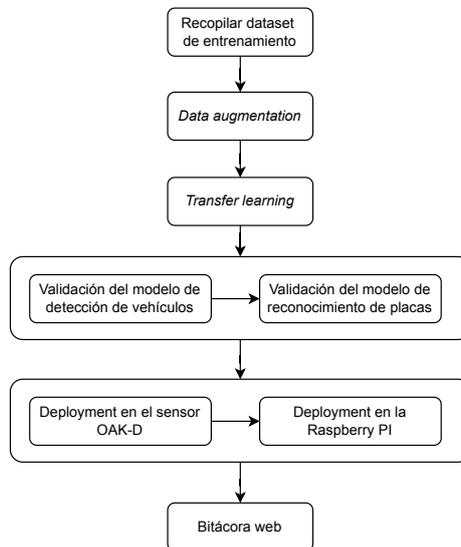


Fig. 3. Descripción del método.

- Crear el módulo OCR. Desarrollar el script para convertir la imagen de la matrícula a texto empleando PaddleOCR.
- Crear el servicio web de bitácora de acceso. Desarrollar el script para almacenar en una base de datos el número de matrícula, además de la hora y fecha en que se identificó el vehículo.

En la Figura 3 se muestran los pasos a seguir durante el desarrollo de la metodología.

5. Propuesta

En [7] se menciona que la inteligencia artificial es utilizada en ámbitos en los que se registran tareas repetitivas, el uso de grandes volúmenes de información, riesgo de vida y extrema complejidad en la resolución de problemas. Esta tendencia es la motivación para enfrentar el problema de la identificación de vehículos de manera automática mediante aprendizaje profundo con un desempeño aceptable.

El desempeño del sistema se analizará mediante las métricas *precision* y *recall*, que son utilizadas principalmente para la evaluación de métodos de detección de objetos[13]. Estas métricas serán calculadas tanto para el modelo de detección de matrículas como para el modelo de OCR de la matrícula. La métrica *precision* indica la habilidad del modelo para identificar solamente objetos relevantes, es decir, el porcentaje de predicciones positivas correctas [19]. Por su parte, *recall* mide la capacidad de un modelo para encontrar todos los

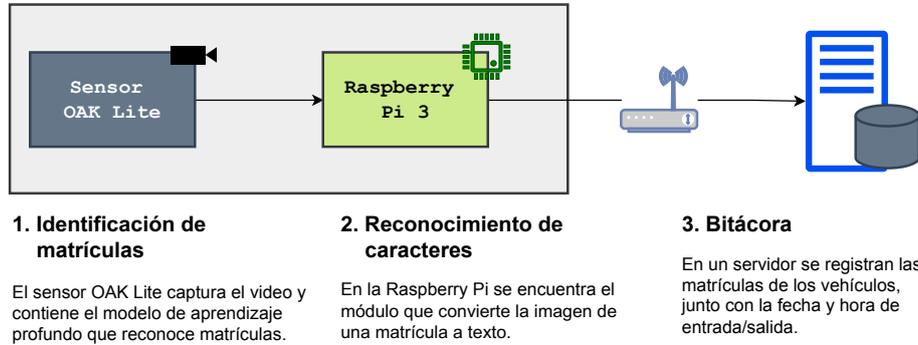


Fig. 4. Componentes y esquema de funcionamiento de la propuesta.

casos relevantes, en otras palabras, es el porcentaje de predicciones positivas correctas de todos los casos reales [20]. A continuación se puede observar el cálculo de *precision* y *recall*:

$$\text{Precision} = P = \frac{TP}{(TP + FP)} = \frac{TP}{\text{Todas las detecciones}}, \quad (1)$$

$$\text{Recall} = R = \frac{TP}{(TP + FN)} = \frac{TP}{\text{Todos los objetos reales}}. \quad (2)$$

Existen varios tipos de cámaras de video con diferentes características, todas cumpliendo la función de capturar y extraer información visual en tiempo real. Sin embargo, al utilizar el dispositivo OAK Lite en nuestro sistema, los datos obtenidos por el dispositivo pasarán directamente al modelo de red neuronal contenido dentro del mismo dispositivo. Es decir, no es necesario convertir el video obtenido por alguna cámara para poder ejecutar el modelo de detección de la placa del vehículo y así reconocer los caracteres mediante PaddleOCR.

El enfoque utilizado en este trabajo impacta en los siguientes rubros:

Computacional. Mediante la elección del aprendizaje profundo como enfoque para modelar el problema.

Social. Mediante el objetivo de procurar la seguridad y el orden entre los individuos y vehículos del lugar del proyecto.

Económico. Mediante la aportación de un sistema simple que requiere muy poca tecnología y equipo.

El Campus Chontalpa cuenta con cobertura de WiFi en todas sus áreas, por lo que es viable colocar el sensor OAK Lite conectado a una Raspberry Pi para poder enviar los resultados obtenidos (caracteres de la matrícula, fecha y hora de acceso) a un servidor dentro de la red UJAT. En la Figura 4 se muestra un esquema general del funcionamiento de nuestra propuesta.

El modelo propuesto estará limitado a identificar solo vehículos, no a sus pasajeros, esto con el fin de garantizar la privacidad. El sensor OAK Lite estará

fijo justo en la entrada del campus. Debido a los horarios de trabajo y de clases, el sistema se entrenará y funcionará durante el día, con luz solar. Es decir, no se utilizará ningún tipo de luz artificial.

Finalmente, mediante la combinación de las bondades del aprendizaje profundo y del OCR se aborda el problema de la identificación de vehículos con fines de vigilancia y control.

6. Conclusiones

Con la implementación de esta propuesta esperamos obtener beneficios no solo en seguridad, sino también en la facilidad para el control de acceso vehicular en el Campus Chontalpa de la UJAT. Se pretende que la implementación del sistema sea simple y la adquisición de materiales sea accesible económicamente, de tal manera que pueda ser replicado en diferentes instituciones, fraccionamientos, carreteras, parques industriales, entre otros.

Agradecimientos. Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el apoyo a la Maestría en Ciencias de la Computación de la Universidad Juárez Autónoma de Tabasco.

Referencias

1. Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., Devin, M., Ghemawat, S., Irving, G., Isard, M., Kudlur, M., Levenberg, J., Monga, R., Moore, S., Murray, D., Steiner, B., Tucker, P., Vasudevan, V., Warden, P., Wicke, M., Yu, Y., , Zheng, X.: TensorFlow: A System for Large-Scale Machine Learning. In: 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16). pp. 265–283 (2016)
2. Ahmad, I. S., Boufama, B.: Automatic Vehicle Identification through Visual Features. In: Proceedings of the 17th International Conference on Advances in Mobile Computing & Multimedia. pp. 185–194. MoMM2019, Association for Computing Machinery, New York, NY, USA (2019) doi: 10.1145/3365921.3365938
3. Ahmed, W., Arafat, S. Y., Gul, N.: A Systematic Review on Vehicle Identification and Classification Techniques. In: 2018 IEEE 21st International Multi-Topic Conference (INMIC). pp. 1–6 (2018) doi: 10.1109/INMIC.2018.8595585
4. Albawi, S., Mohammed, T. A., Al-Zawi, S.: Understanding of a convolutional neural network. In: 2017 International Conference on Engineering and Technology (ICET). pp. 1–6. IEEE (2017) doi: 10.1109/ICEngTechnol.2017.8308186
5. Aldea, E. L.: Raspberry PI fundamentos y aplicaciones. Grupo Editorial RA-MA (2017)
6. Arias, N.: Se disparan los robos en escuelas públicas de Tabasco, (10 2021)
7. Azar, M. A., Tapia, M., García, J. L., Pérez, A. J. M.: Inteligencia artificial de las cosas. In: XXI Workshop de Investigadores en Ciencias de la Computación (WICC 2019, Universidad Nacional de San Juan) (2019)
8. Álvarez Bazo, F., Sánchez-Cambronero, S., Vallejo, D., Glez-Morcillo, C., Rivas, A., Gallego, I.: A Low-Cost Automatic Vehicle Identification Sensor for Traffic Networks Analysis. *Sensors*, vol. 20, no. 19 (2020) doi: 10.3390/s20195589

9. Griese, M. G., Kleinschmidt, J. H.: Performance Analysis of a System for Vehicle Identification Using LoRa and RFID. In: Miani, R., Camargos, L., Zarpelão, B., Rosas, E., Pasquini, R. (eds) *Green, Pervasive, and Cloud Computing*. pp. 115–127. Springer International Publishing, Cham (2019)
10. Hendry, Chen, R.-C.: Automatic License Plate Recognition via sliding-window darknet-YOLO deep learning. *Image and Vision Computing*, vol. 87, pp. 47–56 (2019) doi: 10.1016/j.imavis.2019.04.007
11. Huang, J., Rathod, V., Sun, C., Zhu, M., Korattikara, A., Fathi, A., Fischer, I., Wojna, Z., Song, Y., Guadarrama, S., Murphy, K.: Speed/accuracy trade-offs for modern convolutional object detectors. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. pp. 7310–7311 (2017) doi: 10.1109/CVPR.2017.351
12. Izidio, D. M., Ferreira, A. P., Barros, E. N.: An Embedded Automatic License Plate Recognition System using Deep Learning. In: *2018 VIII Brazilian Symposium on Computing Systems Engineering (SBESC)*. pp. 38–45. IEEE (2018) doi: 10.1109/SBESC.2018.00015
13. Kaur, J., Singh, W.: Tools, techniques, datasets and application areas for object detection in an image: a review. *Multimedia Tools and Applications*, pp. 1–55 (2022)
14. LeCun, Y., Bengio, Y., Hinton, G.: Deep learning. *Nature*, vol. 521, no. 7553, pp. 436–444 (2015)
15. Lin, T.-Y., Goyal, P., Girshick, R., He, K., Dollár, P.: Focal loss for dense object detection. In: *Proceedings of the IEEE International Conference on Computer Cision*. pp. 2980–2988 (2017) doi: 10.1109/ICCV.2017.324
16. Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., Berg, A. C.: SSD: Single shot multibox detector. In: *European conference on computer vision*. pp. 21–37. Springer (2016)
17. Mondal, M., Mondal, P., Saha, N., Chattopadhyay, P.: Automatic number plate recognition using CNN based self synthesized feature learning. In: *2017 IEEE Calcutta Conference (CALCON)*. pp. 378–381. IEEE (2017) doi: 10.1109/CALCON.2017.8280759
18. Montes, S.: Desde tuberías arrancadas a miles de pesos en equipo electrónico: Las escuelas mexicanas son saqueadas durante la pandemia, (05 2021)
19. Padilla, R., Netto, S. L., da Silva, E. A. B.: A Survey on Performance Metrics for Object-Detection Algorithms. In: *2020 International Conference on Systems, Signals and Image Processing (IWSSIP)*. pp. 237–242 (2020) doi: 10.1109/IWSSIP48289.2020.9145130
20. Padilla, R., Passos, W. L., Dias, T. L. B., Netto, S. L., da Silva, E. A. B.: A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit. *Electronics*, vol. 10, no. 3 (2021) doi: 10.3390/electronics10030279
21. Ramírez-Sánchez, R. D.: Del edén al infierno: inseguridad y construcción estatal en Tabasco. *LiminaR*, vol. 17, no. 2, pp. 196–216 (2019)
22. Redmon, J., Divvala, S., Girshick, R., Farhadi, A.: You only look once: Unified, real-time object detection. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. pp. 779–788 (2016) doi: 10.1109/CVPR.2016.91
23. Selmi, Z., Halima, M. B., Alimi, A. M.: Deep learning system for automatic license plate detection and recognition. In: *2017 14th IAPR international conference on document analysis and recognition (ICDAR)*. vol. 1, pp. 1132–1138. IEEE (2017) doi: 10.1109/ICDAR.2017.187

24. Tang, K., Cao, Y., Chen, C., Yao, J., Tan, C., Sun, J.: Dynamic origin-destination flow estimation using automatic vehicle identification data: A 3D convolutional neural network approach. vol. 36, pp. 30–46. Wiley Online Library (2021)
25. Tourani, A., Shahbahrami, A., Soroori, S., Khazaei, S., Suen, C. Y.: A robust deep learning approach for automatic iranian vehicle license plate detection and recognition for surveillance systems. *IEEE Access*, vol. 8, pp. 201317–201330 (2020) doi: [10.1109/ACCESS.2020.3035992](https://doi.org/10.1109/ACCESS.2020.3035992)
26. Vibha, L., Shenoy, P., Venugopal, K., Patnaik, L.: Moving vehicle identification using background registration technique for traffic surveillance. In: *Proceedings of the International MultiConference of Engineers and Computer Scientists*. vol. 1, pp. 19–21. IMECS (2018)
27. Wang, H., Yu, Y., Cai, Y., Chen, X., Chen, L., Liu, Q.: A comparative study of state-of-the-art Deep learning algorithms for vehicle detection. *IEEE Intelligent Transportation Systems Magazine*, vol. 11, no. 2, pp. 82–95 (2019) doi: [10.1109/MITS.2019.2903518](https://doi.org/10.1109/MITS.2019.2903518)
28. Yanes Pérez, M., Canto Valdés, L. R., López López, M.: La percepción de la inseguridad pública en Cunduacán, Tabasco. *Península*, vol. 17, no. 1 (2022)
29. Yang, W., Zhang, J., Wang, H., Zhang, Z.: A vehicle real-time detection algorithm based on YOLOv2 framework. In: *Real-Time Image and Video Processing 2018*. vol. 10670, pp. 106700N. International Society for Optics and Photonics (2018)
30. Yang, X., Tang, Y. Y., Luo, H.-W., Wu, T., Sun, L., Li, L.: One sample based feature learning for vehicle identification. In: *2016 International Conference on Machine Learning and Cybernetics (ICMLC)*. vol. 2, pp. 1049–1054 (2016) doi: [10.1109/ICMLC.2016.7873024](https://doi.org/10.1109/ICMLC.2016.7873024)
31. Zhang, B., Huang, S., Zhang, L., Liu, X., Song, G., Qin, J., Li, M.: Method of railway shunting operation sheet information extraction guided by table header. *IET Intelligent Transport Systems*, vol. 2022, no. 16 (2022) doi: [10.1049/itr2.12213](https://doi.org/10.1049/itr2.12213)