

Detección y reconocimiento de placas patentes utilizando la arquitectura SSD: Un enfoque basado en redes neuronales convolucionales

License plate detection and recognition using the SSD architecture: An approach based on convolutional neural networks

Anibal Laura Huanacuni^{1*}  <https://orcid.org/0009-0005-8066-8717>

Diego Aracena-Pizarro^{1*}  <https://orcid.org/0009-0002-9182-7654>

Recibido 09 de diciembre de 2024 aceptado 14 de julio de 2025

Received: December 09, 2024 Accepted: July 14, 2025

RESUMEN

Este trabajo presenta el desarrollo y evaluación de un modelo para la detección y reconocimiento de placas patentes chilenas, empleando la arquitectura Single Shot Multibox Detector (SSD) con MobileNet v2 para la detección de matrículas, junto con EasyOCR para el Reconocimiento Óptico de Caracteres (OCR). El modelo SSD fue entrenado con un conjunto de imágenes de vehículos de diversos tipos, utilizando patentes chilenas las cuales fueron extraídas de (portales de venta .cl, redes sociales) y luego completadas con imágenes adicionales (capturadas en Arica). Para evaluar la precisión del sistema, se integró el modelo SSD con EasyOCR en un solo sistema funcional que permite tanto la detección como el reconocimiento de los caracteres de las placas.

El objetivo de este estudio es mostrar la eficiencia del modelo SSD en la detección de placas patentes y destacar el potencial que tiene para seguir avanzando en esta área de investigación, ya que existen muchos estudios sobre la detección de objetos, sin embargo, la gran mayoría de estos se basan en enfoque más conocidos como el modelo YOLO o Faster R-CNN. Los resultados obtenidos muestran una precisión del 100% en la detección de placas utilizando el modelo SSD, en cuanto a la detección y reconocimiento de caracteres, se alcanzó una precisión del 94%, lo que demuestra la efectividad de la arquitectura SSD con EasyOCR.

Se discuten las implicaciones prácticas de este sistema y las posibles mejoras futuras en la detección y reconocimiento de caracteres, sugiriendo que la combinación de SSD con EasyOCR es una solución eficiente para el reconocimiento de placas patentes en escenarios del mundo real.

Palabras clave: Detección de objetos, reconocimiento de placas, redes neuronales convolucionales, SSD, MobileNet v2, ANPR, visión computacional.

ABSTRACT

This work presents the development and evaluation of a model for the detection and recognition of Chilean license plates, using the Single Shot Multibox Detector (SSD) architecture with MobileNet v2 for license plate detection, together with EasyOCR for Optical Character Recognition (OCR). The SSD model was trained with a set of images of vehicles of various types, using Chilean license plates extracted from (.cl sales portals and social networks) and then completed with additional images

¹ Universidad de Tarapacá. Facultad de Ingeniería. Departamento de Ingeniería en Computación e Informática. Arica, Chile.
E-mail: anibal.laura.huanacuni@alumnos.uta.cl; daracena@academicos.uta.cl

* Autor de correspondencia: anibal.laura.huanacuni@alumnos.uta.cl; daracena@academicos.uta.cl

(captured in Arica). To evaluate the system's accuracy, the SSD model was integrated with EasyOCR in a single functional system that allows both the detection and recognition of license plate characters. The objective of this study is to show the efficiency of the SSD model in the detection of license plates and to highlight the potential it has to continue advancing in this area of research since there are many studies on object detection; however, the vast majority of these are based on better-known approaches such as the YOLO model or Faster R-CNN. The results show a 100% accuracy in license plate detection using the SSD model. For character detection and recognition, an accuracy of 94% was achieved, demonstrating the effectiveness of the SSD architecture with EasyOCR.

The practical implications of this system and possible future improvements in character detection and recognition are discussed, suggesting that the combination of SSD with EasyOCR is an efficient solution for license plate recognition in real-world scenarios.

Keywords: Object detection, license plate recognition, convolutional neural networks, SSD, MobileNet v2, ANPR, computer vision.

INTRODUCCIÓN

El uso de modelos de detección de objetos y clasificación de imágenes es fundamental en diversas aplicaciones de visión por computadora. Entre estos, los modelos basados en redes neuronales convolucionales (CNN) han ganado una notable popularidad debido a su eficacia y precisión en múltiples tareas y aplicaciones del mundo real.

Para la detección y reconocimiento de placas patentes, se han utilizado diversos métodos con el objetivo de mejorar la precisión, ya que esta área sigue en constante evolución. Los primeros métodos de reconocimiento automático de matrículas (ANPR) utilizan técnicas de procesamiento de imágenes avanzados, en general estos enfrentan limitaciones relacionadas con cambios de luz, ángulos de visión y calidad de imágenes, sin embargo, en contextos específicos estos resultan ser bastante eficientes [1]. En [2] se menciona que el ANPR ha sido popular en múltiples campos científicos como la ciencia urbana, la visión por computadora y la gestión del transporte.

Con el surgimiento de las redes neuronales convolucionales, se han implementado diversos modelos de detección de objetos, entre los más destacados se encuentra Fast-RCNN [3], YOLO [4], y técnicas anteriores como la búsqueda selectiva para el reconocimiento de objetos [5], que soluciona muchos de los problemas de los métodos tradicionales al ser invariante a cambios de iluminación, ángulos de visión y mejoran significativamente la detección en imágenes de baja calidad.

En este estudio, se presenta un modelo de detección de placas patentes basado en la arquitectura SSD (Single Shot Multibox Detector) [6]. La arquitectura SSD es un modelo de detección de objetos de una sola etapa que utiliza un modelo base de clasificación, específicamente MobileNet v2 [7], compuesto por varias capas. SSD añade capas adicionales utilizando los mapas de características que entrega el modelo base. Por cada capa de convolución, la resolución de la imagen va disminuyendo, lo que hace que SSD sea bastante preciso. Para la etapa de entrenamiento se dispone de un total de 750 imágenes de vehículos chilenos, todas estas extraídas de portales de ventas de autos .cl e imágenes propias capturadas en Arica. Se realizan pruebas de detección para evaluar la precisión del modelo en diferentes contextos y tipos de imágenes, utilizando el 20% del total de las imágenes, ya que el 80% es utilizado para el entrenamiento del modelo SSD. Para el reconocimiento de caracteres, se utiliza el modelo EasyOCR, un reconocimiento óptico de caracteres (OCR) de uso libre, este resulta ser bastante eficiente en esta etapa de reconocimiento.

El objetivo de este trabajo es evaluar la precisión y eficiencia de la arquitectura SSD en la detección de placas patentes, y demostrar que la integración con EasyOCR puede ser efectiva en escenarios del mundo real y también ofrecer una solución aplicable a otras áreas de investigación, como la vigilancia y el control de acceso. Este trabajo no solo contribuye al campo de la detección de matrículas, sino que también ofrece una base para futuras investigaciones que busquen implementar estos modelos en aplicaciones más amplias, ya que

normalmente, muchos trabajos se basan en modelos más conocidos como YOLO o Fast-RCNN.

TRABAJOS RELACIONADOS

En la literatura, Rojas Henríquez y Aracena Pizarro [1], presentan el empleo de técnicas de agrupamiento para segmentar patentes vehiculares mediante un método aplicable a sistemas ANPR (Automatic Number Plates Recognition). Para lograrlo se realizaron diferentes pruebas con clusters, este método utiliza técnicas de agrupamiento para eliminar, de manera automática, los puntos espurios que pueden ser generados por las técnicas de obtención de correspondencias. Para realizar la segmentación de patentes vehiculares, el método recibe como entrada una nube de puntos correspondientes, resultantes de un matching entre los descriptores SIFT (Scale Invariant Features Transforms) de la imagen de entrada y los descriptores SIFT de una imagen de referencia que contiene los posibles caracteres de una patente vehicular. Mediante técnicas de agrupamiento se obtiene el cluster conformado por los puntos ubicados en la zona de la placa y además su centroide asociado. Luego se emplea la técnica de crecimiento de regiones para segmentar el área mínima que encapsula al centroide, la cual constituye la placa patente de la imagen considerada.

Hendry and Chen [8] utilizan el modelo YOLO para la detección y reconocimiento de placas patentes. Su trabajo propone detectar la placa patente y los caracteres en una sola etapa, logrando aproximadamente un 98,22% de precisión en la detección de matrículas y un 78% de precisión en el reconocimiento de matrículas. El sistema ejecuta una única fase de reconocimiento de detección, que necesita entre 800 ms y 1 s para cada imagen de entrada.

Puarungroj and Boonsirisumpun [9] presentan un proceso de reconocimiento de matrículas basado en aprendizaje profundo. La investigación se centra en reconocer las matrículas de motocicletas tailandesas, que son del tipo de matrícula de triple línea. Utilizan el modelo SSD para detectar cada línea de la patente de manera independiente y reconocer los caracteres. Los resultados obtenidos para detectar los caracteres variaron entre 91% y 96%.

Tang *et al.* [2] presentan una revisión sistemática del estado actual y las aplicaciones del Reconocimiento

Automático de Placas de Vehículos (ANPR) en el contexto de ciudades inteligentes. En su análisis, los autores destacan el rol de ANPR en la transformación de las ciudades, señalando su contribución en la recopilación de grandes volúmenes de datos de tráfico que permiten monitorear patrones de movilidad. Esta tecnología ha sido implementada en más de 75 países, siendo un recurso clave para enfrentar desafíos urbanos como la congestión, la contaminación y la seguridad. El estudio revisa tres áreas específicas: primero, los avances tecnológicos en ANPR; segundo, los factores que influyen en su rendimiento en distintos contextos; y tercero, los casos de uso y las implicancias prácticas de su implementación desde una perspectiva de usuario. Además, presentan un análisis detallado de casos de uso prácticos, como la implementación de ANPR en la zona de peaje de Londres, uno de los proyectos más representativos en la gestión inteligente del tráfico en una megaciudad. Este enfoque multidimensional convierte a su artículo en una valiosa referencia tanto para el desarrollo teórico como para aplicaciones prácticas de ANPR en el ámbito de las ciudades inteligentes.

En conjunto, estos estudios demuestran la importancia de desarrollar técnicas avanzadas de segmentación y reconocimiento de placas vehiculares para mejorar la precisión y eficiencia de los sistemas de Reconocimiento Automático de Placas Patentes (ANPR) en aplicaciones prácticas. Las investigaciones revisadas abordan tanto los desafíos técnicos como las implicaciones en diversos contextos urbanos complejos, la variedad de enfoques utilizados, como la segmentación basada en agrupamiento y la detección unificada de YOLO y SSD, evidencia que, si bien se han logrado avances significativos, todavía existen oportunidades para optimizar y adaptar estas tecnologías a contextos específicos. A partir de estos antecedentes, esta investigación se enfoca en explorar y evaluar el uso de la arquitectura SSD en combinación con EasyOCR, con el fin de contribuir a la evolución y mejora de los sistemas ANPR, particularmente en entornos de tráfico real mediante redes neuronales convolucionales (CNN).

METODOLOGÍA

Arquitectura SSD(Single Shot Detect Multi Box)

El modelo SSD es un detector de objetos que sobresale en la detección rápida y precisa de múltiples

categorías. En Liu *et al.* [6] se compara con otros detectores de un solo disparo como YOLO [4], y como resultado, SSD ofrece una mayor precisión, similar a técnicas más lentas que utilizan propuestas de regiones explícitas, como Faster R-CNN [3].

La esencia de SSD radica en su capacidad para predecir tanto las puntuaciones de las categorías como los desplazamientos de los cuadros delimitadores para un conjunto fijo de estos cuadros, utilizando pequeños filtros convolucionales aplicados a diferentes mapas de características.

Para garantizar una alta precisión en la detección, SSD genera predicciones a partir de múltiples escalas, utilizando mapas de características de diferentes tamaños y haciendo predicciones separadas según la relación de aspecto de los objetos. Estas características de diseño facilitan un entrenamiento de extremo a extremo, permitiendo que SSD mantenga una alta precisión incluso con imágenes de entrada de baja resolución, equilibrando de manera efectiva la velocidad y la precisión.

El marco de SSD funciona de la siguiente manera: De la Figura 1a, durante el entrenamiento, SSD solo requiere una imagen de entrada y los cuadros delimitadores de referencia (ground truth) para cada objeto. De manera convolucional, evalúa un pequeño conjunto (por ejemplo, 4) de cuadros predeterminados con diferentes relaciones de aspecto en cada ubicación de varios mapas de características de diferentes tamaños (por ejemplo, 8×8 y 4×4 , como se muestra en Figura 1b y Figura 1c. Para

cada cuadro predeterminado, SSD predice tanto los desplazamientos de forma, representados por los parámetros *loc*: $(\Delta(cx, cy, w, h))$, que indican las modificaciones en las coordenadas del centro y en las dimensiones del cuadro delimitador, como las puntuaciones de confianza *conf*: $(c_1, c_2, \dots, c_p)$ para todas las categorías de objetos. Las puntuaciones de confianza reflejan la probabilidad de que el objeto dentro de cada cuadro predeterminado pertenezca a una clase específica, permitiendo al modelo seleccionar el tipo de objeto detectado y su ubicación precisa.

Modelo

El método SSD se basa en una red convolucional de avance que genera una colección fija de cuadros delimitadores y puntuaciones para la presencia de instancias de clase de objeto en esos cuadros (Figura 2). Luego, un paso de supresión no máxima produce las detecciones finales. Las primeras capas de la red utilizan una arquitectura estándar para la clasificación de imágenes de alta calidad MobileNet V2 [7], conocida como la red base. Posteriormente, se añade una estructura auxiliar a esta red para producir detecciones con las siguientes características clave:

- **Mapas de características multiescala para detección:** SSD utiliza mapas de características de diferentes escalas para manejar objetos de distintos tamaños.
- **Predictores convolucionales para detección:** Pequeños filtros convolucionales se utilizan para predecir las puntuaciones y los desplazamientos de los cuadros delimitadores.

Fuente: [6].




Figura 1. a) Imagen con cajas GT (Ground Truth), b) Mapa de características de 8×8 , c) Mapa de características de 4×4 .

Fuente: [6]




Figura 2. Arquitectura del modelo SSD(Single Shot Detector).

- **Cajas predeterminadas y relaciones de aspecto:** SSD evalúa un conjunto fijo de cuadros delimitadores con diferentes relaciones de aspecto en cada ubicación de los mapas de características.

PROCESO DE ENTRENAMIENTO

Recopilación de datos

Para el entrenamiento del modelo SSD, se utilizó un conjunto de datos compuesto por 750 imágenes de vehículos con placas patentes chilenas. Estas imágenes fueron extraídas de una fuente abierta (portales de venta.cl, redes sociales, entre otras) y luego complementadas con imágenes adicionales (capturadas en Arica).

Se aseguraron de cubrir una variedad de escenarios, tales como diferentes condiciones de iluminación, ángulos de visión y tipos de vehículos, para garantizar la generalización del modelo.

Preprocesamiento de datos

El proceso de preparación de los datos consta de los siguientes pasos:

- Redimensionado de imagen: Todas las imágenes fueron redimensionadas a 640x640 píxeles para adaptarse al tamaño de entrada requerido por el modelo SSD.
- Etiquetado: Las placas patentes dentro de las imágenes fueron etiquetadas manualmente con cuadros delimitadores (bounding boxes) utilizando la herramienta de etiquetado Roboflow [10].

Entrenamiento del modelo

El modelo fue entrenado utilizando el 80% de las 750 imágenes previamente etiquetadas, este proceso se realizó en Google Colab [11] y se utilizó el plan gratuito. Se requiere la versión 2,8 de TensorFlow y la versión 11 de CUDA para aprovechar la GPU y acelerar el proceso de entrenamiento.

Los parámetros configurados son los siguientes:

- Optimización: Se utilizó el optimizador Momentum con una tasa de aprendizaje inicial de 0.07999999821186066.
- Función de activación: Se utiliza la función de activación ReLU6.
- Batch Size: El tamaño del lote fue configurado en 14, y el entrenamiento se llevó a cabo durante 120 épocas equivalente a 6000 pasos.

En la Figura 3 se muestra la tasa de aprendizaje del modelo SSD, donde se observa que entre los pasos 1,2 k y 1,5 k alcanza la tasa máxima de aprendizaje, esta convergencia descendente permite al modelo refinar sus pasos y mejorar su precisión sin realizar cambios drásticos que puedan afectar el aprendizaje de manera negativa.

Funcionamiento del sistema de detección y reconocimiento de matrículas

Para el reconocimiento de los caracteres de las placas detectadas, se integró el modelo de reconocimiento óptico de caracteres EasyOCR, siendo este, un modelo de uso libre ya entrenado. Este modelo es capaz de reconocer textos en imágenes sin necesidad de segmentar manualmente los caracteres, el texto

Fuente: [propia]



Figura 3. Tasa de aprendizaje del modelo.

extraído de cada placa detectada fue validado con las etiquetas reales para medir la precisión.

El funcionamiento del sistema (Figura 4) consta de los siguientes pasos:

- **Preprocesamiento de la imagen:** Una vez cargada la imagen, se procesa para convertirla en un tensor, un tipo especial de array utilizado en el procesamiento de imágenes en TensorFlow.
- **Inferencia de imagen:** Luego, la imagen se procesa con el modelo SSD previamente entrenado para detectar la placa patente.
- **Extracción de la región detectada:** Se aísla la zona detectada (placa patente) para luego detectar los caracteres de la placa.
- **Reconocimiento de la patente utilizando EasyOCR:** En esta etapa, se emplean 3 métodos:
 - a) Método 1: Se pasa la imagen al modelo OCR sin realizar cambios, ya que existe la posibilidad de alterar la forma original y dificultar la detección de caracteres.
 - b) Método 2: Se limpia la imagen para eliminar el ruido y las distorsiones, utilizando técnicas de procesamiento de imágenes.
 - c) Método 3: Se aplica un filtro gaussiano para eliminar el ruido y se reduce el tamaño de la patente para eliminar bordes que podrían interferir con el modelo OCR.

Fuente: [propia].




Figura 4. Funcionamiento del sistema de detección y reconocimiento de placas patentes.

Estos métodos se aplican secuencialmente para optimizar el reconocimiento de patentes en diversas condiciones de imagen.

RESULTADOS

En esta sección, se describen los detalles de los experimentos, el proceso y los resultados. Para una mejor validación, esta sección se divide en dos etapas, la primera valida la precisión del modelo SSD entrenado, es decir la detección de la placa patente. En la segunda etapa se validó la detección y el reconocimiento de los caracteres, en esta etapa utilizamos el modelo SSD con EasyOCR.

Pruebas del modelo SSD

Para esta etapa utilizamos el 20% de las 750 imágenes, a continuación, se presentarán algunas evidencias de los resultados obtenidos.

En la Figura 5, se observa que las imágenes tienen poca iluminación, el modelo igual las detecta con notable precisión. En la Figura 6, las imágenes tienen una iluminación adecuada y se obtuvieron resultados satisfactorios. El número que se encuentra sobre la

placa patente, indica la confianza que tiene el modelo al momento de predecir la patente, por ejemplo en la Figura 6 (imagen 4), el modelo está 99,99% seguro de que esa región es una placa patente. Tras realizar pruebas con todo el dataset, se logró obtener una precisión del 100%, es importante mencionar que aún falta realizar pruebas con imágenes donde los vehículos estén a distancias más lejanas.

Los resultados obtenidos fueron altamente precisos (Tabla 1), alcanzando una precisión máxima del 100%. Es importante destacar que la confianza en la precisión del modelo se mantuvo consistente, oscilando entre el 84% y el 99%.

Pruebas del sistema de detección y reconocimiento

Para esta evaluación, se utilizaron un total de 50 imágenes seleccionadas específicamente para garantizar que las placas fueran claramente visibles. Todas las imágenes seleccionadas fueron adecuadas para llevar a cabo esta prueba.

En la Figura 7 y Figura 8 se aprecia la detección de la placa patente y el reconocimiento de los caracteres utilizando la arquitectura propuesta para el sistema

Fuente: [propia].




Figura 5. Resultados de detección de la placa con condiciones de iluminación variada.

Fuente: [propia].



Figura 6. Resultados de la detección de la placa con buena iluminación.

Tabla 1. Resultados de detección de placas patentes.

Cantidad de imágenes	Cantidad detectadas	Precisión
750	750	100%

Fuente: [propia].

de reconocimiento de matrículas (Figura 4). Los métodos para el reconocimiento de la matrícula se presentan en las siguientes imágenes (Figura 9a y Figura 9b):

Los resultados obtenidos fueron satisfactorios, alcanzando una precisión máxima del 94% en las 50 imágenes evaluadas. Al analizar las causas de las dificultades en la detección de caracteres, se identificaron varios factores que afectan la precisión de reconocimiento, entre ellos, destacan la descomposición de los caracteres, el ángulo de

visión y, especialmente, la calidad de la imagen y el estado físico de las patentes, ya que en imágenes de baja resolución o con patentes dañadas, el reconocimiento se vuelve considerablemente más desafiante. Estas limitaciones se deben, en parte, a que EasyOCR y otros modelos de reconocimiento óptico de caracteres (OCR) de código abierto suelen estar entrenados con una amplia variedad de tipografías y estilos visuales, pero no necesariamente optimizados para reconocer patrones específicos de las placas patentes chilenas. Esto representa una barrera en la precisión del reconocimiento, ya que los modelos OCR generalmente no están especializados en los formatos y características particulares de las matrículas en Chile.

A pesar de estos desafíos, el porcentaje de precisión alcanzado es bastante alto, esto sugiere que la implementación de este sistema de detección y reconocimiento puede ser altamente beneficiosa en aplicaciones del mundo real. Se espera que este trabajo sirva como base para futuras investigaciones,

Fuente: [propia].



Figura 7. Resultados de detección y reconocimiento de la placa patente.

Fuente: [propia].



Figura 8. Resultados de detección y reconocimiento de la placa patente.

Fuente: [propia].



Figura 9. a) Imagen de la patente sin procesamiento, b) imagen de la patente procesada.

aplicaciones de este modelo SSD en diferentes contexto, y se sugiere que el modelo SSD se combine con un detector óptico de caracteres (OCR) entrenado específicamente con caracteres de matrículas chilenas, para mejorar su precisión en estos casos particulares.

CONCLUSIONES

En este estudio, se presentó el uso y la eficiencia de la arquitectura SSD basada en redes neuronales convolucionales para la detección de placas patente. Y además el potencial que tiene este modelo junto con el modelo EasyOCR, para el reconocimiento óptico de caracteres en las placas. El proceso de entrenamiento del modelo SSD, consta desde la recolección de diversos tipos de imágenes para un mejor entrenamiento, el etiquetado de la zona de interés, la configuración del modelo y el entrenamiento. Los resultados obtenidos en la detección de la placa patente fueron bastante precisos, ya que del 20% de 750 imágenes, se obtuvo una precisión del 100%.

El sistema que se propone para la detección y reconocimiento de placas patentes consta de los siguientes pasos: detección de la zona de interés (patente) y extracción de los caracteres mediante tres métodos diferentes. Estos métodos incluyen; 1) usar la imagen original para extraer los caracteres, 2) realizar procesamiento de imagen para dejar más limpio la patente y 3) finalmente solo aplicar un filtro gaussiano a la placa patente y eliminar bordes. Al realizar pruebas de estos métodos, se llegó a la conclusión de que en ocasiones no es necesario realizar alguna alteración a la imagen extraída (placa patente) ya que este proceso puede realizar modificaciones a la imagen y no ser reconocido correctamente.

Como trabajo futuro, se propone implementar un modelo OCR específicamente entrenado con

imágenes de caracteres de placas patentes chilenas, esto podría ser altamente beneficioso, ya que los modelos OCR tradicionales están entrenados con diversas tipografías, formatos y fuentes, lo cual puede introducir sesgos en el reconocimiento de matrículas chilenas.

Se espera que este estudio sea de gran aporte a otras áreas de investigación relacionadas con la visión por computadora y el reconocimiento de patrones, además de inspirar el desarrollo de soluciones prácticas y de alto impacto en aplicaciones del mundo real. La implementación de este modelo de detección y reconocimiento de placas patentes puede extenderse a ámbitos como el control de tráfico, la seguridad vial, la automatización de peajes, y la vigilancia, mejorando la precisión y eficiencia de estos sistemas. Asimismo, los resultados obtenidos y los métodos aplicados en esta investigación podrían servir como base para futuras adaptaciones y optimizaciones en contextos específicos, maximizando el potencial de modelos SSD y de detección en escenarios complejos y con conjuntos de datos personalizados.

REFERENCIAS

- [1] J. Rojas Henriquez y D. Aracena Pizarro, "Segmentación de patentes vehiculares mediante técnicas de agrupamiento en ambientes externos", *Ingeniare. Revista chilena de ingeniería*, vol. 21, no. 2, pp. 172-184, ago. 2013, doi: 10.4067/S0718-33052013000200002
- [2] J. Tang, L. Wan, J. Schooling, P. Zhao, J. Chen, and S. Wei, "Automatic number plate recognition (ANPR) in smart cities: A systematic review on technological advancements and application cases", *Cities*, vol. 129, Art. 103833, Oct. 2022, doi: 10.1016/j.cities.2022.103833.
- [3] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards real-time object

- detection with region proposal networks,” 2015, arXiv: 1506.01497.
- [4] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, Jun. 2016, pp. 779-788, doi: 10.1109/CVPR.2016.91.
 - [5] J.R. Uijlings, K.E. van de Sande, T. Gevers, and A.W. Smeulders, “Selective search for object recognition,” *International Journal of Computer Vision*, vol. 104, pp. 154-171, 2013, doi: 10.1007/s11263-013-0620-5.
 - [6] W. Liu, D. Anguelov, D. Erhan, C.Y. Fu, S. Reed, C. Szegedy, and A.C. Berg, “SSD: Single Shot MultiBox Detector,” in *Computer Vision, ECCV 2016. Lecture Notes in Computer Science*, B. Leibe, J. Matas, N. Sebe, and M. Welling, Eds., vol. 9905, Cham, Switzerland: Springer, pp. 21-37, 2016, doi: 10.1007/978-3-319-46448-0_22016.
 - [7] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.C. Chen, “MobileNetV2: Inverted Residuals and Linear Bottlenecks,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Salt Lake City, UT, USA, jun. 2018, pp. 4510-4520, doi: 10.1109/CVPR.2018.00473.
 - [8] Hendry and R.C. Chen, “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.neunet.2019.01.002.
 - [9] W. Puarungroj and N. Boonsirisumpun, “Thai License Plate Recognition Based on Deep Learning,” in *Proceedings of the 3rd International Conference on Computer Science and Computational Intelligence*, Bangkok, Sep. 2018, pp. 214-221, doi: 10.1016/j.procs.2018.07.034.
 - [10] Roboflow, “Roboflow: Computer vision tools for developers and enterprises,” roboflow.com. Accessed: Nov. 10, 2024. [Online]. Available: <https://roboflow.com/>
 - [11] Google, “Google Colab,” google.com. Accessed: Nov. 10, 2024. [Online]. Available: <https://colab.google/>