

PROTOTIPO DE SISTEMA DE RECONOCIMIENTO DE AUTOMÓVILES

**Enrique Aguilera Rosas Landa¹, Emmanuel Minajas Carbajal¹,
Gustavo Josué Robles Martínez¹, José Félix Serrano Talamantes²,
Mauricio Olguín Carbajal²**

¹Instituto Politécnico Nacional-Escuela Superior de Computo “ESCOM”, México

²Instituto Politécnico Nacional-Centro de Innovación y Desarrollo Tecnológico en
Cómputo “CIDETEC», México

aguilerarosas1195@gmail.com, eminajas@gmail.com, roblesmgustavoj@gmail.com,
jfserrano@ipn.mx, molguinc@ipn.mx

<https://doi.org/10.3926/oms.411.5>

Rosas Landa, E. A., Minajas Carbajal, E., Robles Martínez, G. J., Serrano Talamantes, J. F., & Olgúin Carbajal, M. (2022). Prototipo de sistema de reconocimiento de Automóviles. En M. A. Ramírez Salinas, L. N. Oliva Moreno, L. I. Garay Jimenez y P. Gomez Miranda (Ed.), *Avances 2022: Red de Investigación Computación del Instituto Politécnico Nacional, México* (pp. 79-94). Barcelona, España: OmniaScience.

Resumen

En esta propuesta se desarrolló un prototipo de sistema de reconocimiento de automóviles con el propósito de reconocer automóviles mediante redes neuronales. Las características usadas como discriminantes para reconocer los automóviles son: placa, marca, modelo y color del automóvil. Las diversas redes neuronales se entrenaron con una base de datos de imágenes que nosotros recabamos de diversas plataformas de compra y venta de automóviles. Los resultados de los entrenamientos fueron completamente satisfactorios logrando hasta un 99.0 % de precisión al momento de clasificar diversos automóviles. La razón por la cual catalogamos este proyecto como un “Prototipo” es por que en la Ciudad de México existen un aproximado de 17 marcas de automóviles distintas y cada marca tiene sus propios modelos distintos. Nosotros nos enfocamos en reconocer de momento 7 marcas distintas de automóviles y un total de 31 modelos distintos.

Palabras clave

Análisis de regiones en imágenes, Etiquetado de imágenes, Redes neuronales, Reconocimiento óptico de caracteres, Rasgos discriminantes.

1. Introducción

El robo de autos en México es un tema muy común ya que, cifras de la Asociación Mexicana de Instituciones de Seguros (AMIS) reporta que entre octubre de 2018 y septiembre de 2019 se hurtaron en toda la República Mexicana 88 mil 047 automóviles asegurados [1].

En el mes de agosto del año 2019 se han presentado 8,548 autos, de estos 1,069 por mes o 35 por día, de los cuales el 30 % se cometió con violencia [2]. Las alcaldías que registraron mayor índice de robo fueron Iztapalapa, Gustavo A. Madero y Coyoacán. Estas dos primeras reportan que los delitos se presentan de forma más violenta con un promedio del 40 % los cuales fueron a mano armada [1].

Los autos que se roban en la actualidad tienen tres destinos: la comercialización en otros estados, mediante papeles apócrifos, venta de auto partes y actividades ilícitas. Algunos expertos consideran que las autoridades deben reforzar los esfuerzos para recuperar más automóviles, y también la industria deben analizar y generar propuestas para combatir el delito y recuperar los automóviles [2].

Nos enfocamos principalmente en los automóviles que circulan en la Ciudad De México porque el número de carpetas de investigación que se generaron bajo el nombre de “Robo de vehículo con y sin violencia” entre noviembre del 2018 al 2019 ocupan el tercer lugar de los delitos más frecuentes.

Estos datos se pueden ver reflejados en la Tabla 1 la cual contiene datos proporcionados por la Procuraduría General de Justicia de la Ciudad De México.

Número de Carpetas de investigación en la Ciudad de México	
Delito de bajo impacto	86,005
Robo a transeúnte en vía pública	8,259
Robo de vehículo	6,809
Robo a negocio	2,636
Hecho no delictivo	2,224

Tabla 1. Top 5 de carpetas de investigación generadas en la Ciudad De México [4]

Teniendo estos datos en cuenta se investigó sobre el número de automóviles en promedio que están asegurados en México obteniendo datos reveladores que nos indican que sólo 3 de cada 10 automóviles están asegurados y entre noviembre del 2018 al 2019 un total de 93,000 automóviles asegurados fueron robados. Con estos datos estimamos que se robaron un total de 310,000 automóviles y una pérdida en valor comercial aproximada de 14 mil millones de pesos en pérdidas.

Para el desarrollo de esta propuesta, se usó la técnica de “Deep Learning” la cual se trata de un algoritmo de aprendizaje automático que imita la percepción humana mediante el uso de redes neuronales artificiales, con el fin de identificar, reconocer y clasificar objetos presentes en una imagen. Este proceso se logra expresar de manera gráfica en la Figura 1.

1.1. Objetivo

Desarrollar e implementar un prototipo de aplicación web con tecnología de redes neuronales capaz de analizar, reconocer y almacenar automóviles automotores (4 ruedas) obtenidos por cámaras o imágenes.

1.1.1. Objetivos Particulares:

- Reunir información referente al robo y recuperación de automóviles en el país y Ciudad de México.

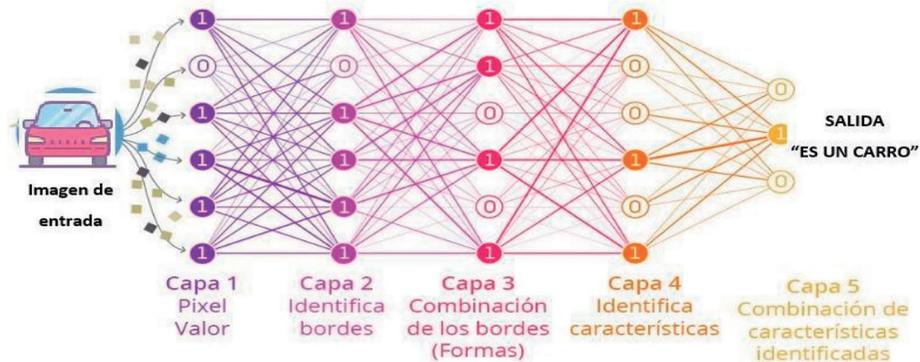


Figura 1. Detección y clasificación de una red neuronal

- Realizar un análisis de los problemas relacionados con el reconocimiento de automóviles utilizando redes neuronales y desarrollar una aplicación
- Realizar pruebas de factibilidad pertinentes que requiera el desarrollo.

1.2. Base de datos de imágenes

La base datos que recopilamos consta de un total de 10,212 imágenes diferentes de automóviles de distintos ángulos los cuales abarcan tomas frontales, traseras, 2 de cada costado del vehículo y 4 de cada uno de los ángulos diagonales de los carros. La base de datos de imágenes se compone de la siguiente cantidad de imágenes: carros 4 puertas (3,500 imágenes), camionetas (2,000), SUV (2,712), camiones (2,000). Las imágenes cuentan con una resolución de: 1600x1067px, un tamaño promedio de 208kb y una antigüedad no mayor a 4 años. En la Figura 2 se muestran una serie de imágenes las cuales componen una pequeña parte de las bases de datos.



Figura 2 Base de datos de automóviles. (a) Carro Chevrolet Aveo Frontal; (b) Carro Chevrolet Aveo Trasera; (c) Carro Ford Passat Frontal-Diagonal; (d) SUV Lateral; (e) Carro Nissan Versa Trasera-Diagonal; (f) Camioneta Suburban Lateral

1.3. Herramientas utilizadas

Las herramientas que se utilizaron para este proyecto son: lenguaje de programación “Python” en su versión 3, app de etiquetado de imágenes “Label Image” [5], “Firebase” para almacenar las imágenes de los automóviles que se detectaron y sus rasgos distintivos [6], “OpenALPR” [7] para realizar el proceso de detección de caracteres alfanuméricos en la placa, “WebFlow” [8] para hospedar el sitio de nuestro proyecto y “Google Colaboratory” [9], la cual nos fue de bastante utilidad para entrenar las diversas redes neuronales, permitiéndonos realizar entrenamientos con GPU y almacenamiento en la nube.

2. Metodología

La metodología utilizada en el trabajo presente se describe en las Figuras 3 y 4. En estas dos figuras mostramos de manera gráfica las 2 partes importantes para llevar a cabo el desarrollo de este proyecto.

Parte 1. Etiquetado y entrenamiento de las redes neuronales

El proceso de etiquetado de las imágenes se realizó leyendo primero la imagen que se requiere etiquetar, en este caso la denominamos como imagen original, una vez que contamos con la imagen original se procede a realizar un etiquetado de todas las características visibles del automóvil, por ejemplo el tipo de vehículo, la marca y el modelo, como resultante obtenemos nuestra imagen etiquetada, las etiquetas se guardan en un archivo de formato “.txt”; una vez que tenemos



Figura 3. Proceso de etiquetado de imagen y entrenamiento de la red neuronal

nuestras imágenes y etiquetas en una carpeta se procede a realizar la carga en una carpeta de Google drive con el fin de realizar el entrenamiento en la nube y guardar todas nuestras redes neuronales en nuestra cuenta de Google drive. Para este proyecto se entrenaron un total de 23 redes neuronales las cuales se hacen mención en la Tabla 2.

En la Tabla 3 mencionamos las clases que son capaces de reconocer cada una de las redes neuronales.

Al tener una red neuronal capaz de detectar el tipo de logo, nos ayuda a disminuir el número de clases que debe de reconocer el detector de modelo, simplificando un total de 31 automóviles distintos, nosotros reducimos el problema en pequeñas partes a reconocer un tipo de vehículo de una determinada marca. Reduciendo los resultados de 1/31 parte a 1/4 como máximo (tomando de ejemplo los carros de Volkswagen). En la tabla 4 se mencionan todos los modelos que reconocemos con su respectiva marca.

Red Neuronal	Cantidad
Detector de tipo de vehículo	1
Detector de Logos	1
Detector de Modelos	21
Total, de Redes Neuronales	23

Tabla 2. Redes neuronales entrenadas

Red Neuronal	Clases a reconocer
Detector de tipo de vehículo	Carro, Camión, Camioneta, SUV
Detector de Logos	Chevrolet, Ford, Honda, Nissan, Toyota, Volkswagen

Tabla 3. Clases automóviles y logos que reconocemos

Detector de Modelos				
Marca	Carros	Camioneta	SUV	Camión
Chevrolet	Aveo, Beat	Silverado, Suburban	Trax	–
Ford	Fusion, Focus, Figo	F-150, Explorer	–	–
Honda	City, Civic, Fit	Odyssey	CRV	–
Kenworth	–	–	–	Kenworth
Nissan	Sentra, Tsuru, Versa	NP300	Kicks	–
Toyota	Corolla, Prius, Yaris	Tacoma	Rav4	–
Volkswagen	Gol, Jetta, Passat, Vento	–	Tiguan	–

Tabla 4. Clases de modelos que reconocemos

Parte 2. Detección y clasificación de los automóviles

El proceso completo de clasificación de los automóviles considera la obtención de una fotografía o video donde se encuentren circulando los automóviles. Después se realiza una segmentación y redimensión de la imagen para su análisis

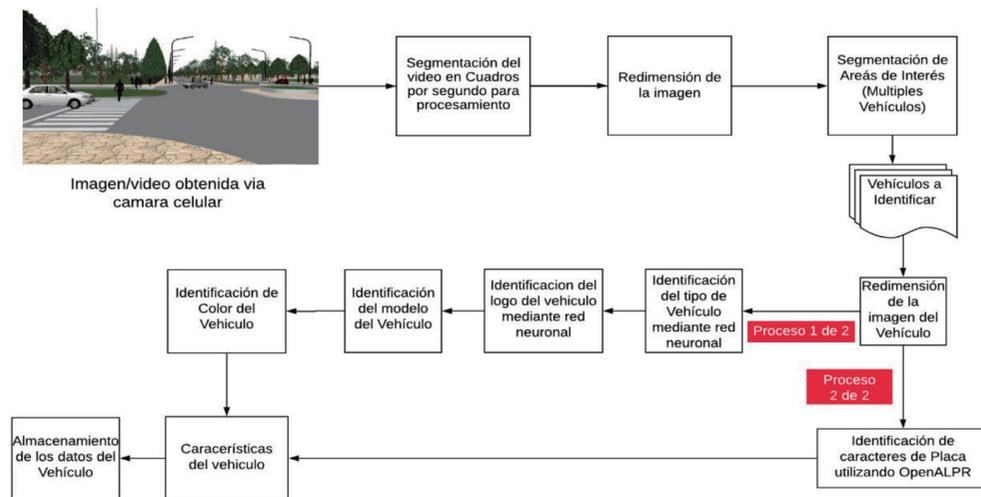


Figura 4. Flujo de la metodología para la clasificación del automóvil

con el fin de segmentar nuestra área de interés la cual definimos nosotros como cualquier área donde se encuentre 1 o más automóviles. Una vez que obtenemos todos los automóviles que se detectaron, se procede a realizar una redimensión una vez más pero ahora únicamente de la imagen del automóvil. A partir de aquí todo nuestro proceso se divide en 2 etapas o procesos.

Etapas 1

Consiste en enfocarnos en detectar primero el tipo de automóvil (carro, camioneta, camión o SUV), una vez que se ha detectado se procede a identificar el tipo de marca (Chevrolet, Ford, Honda, Kenworth, Nissan, Toyota, Volkswagen). Una vez logrado lo anterior, se procede a cargar el algoritmo de la red neuronal especializada en detectar ese tipo de automóvil de la marca, así podemos ofrecer un resultado de clasificación más preciso. Este proceso se muestra en la Figura 5.



Figura 5 Proceso de clasificación de automóvil

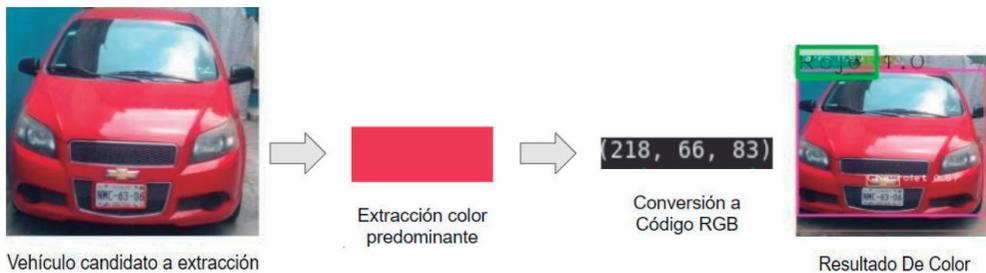


Figura 6. Extracción de color predominante

Una vez que obtenemos las características anteriores del automóvil se procede a obtener el color que más predomina en la imagen aplicando la técnica de formación de clústeres de los K-Centros (K-means), y se obtiene el color que más predomina, de esta forma procedemos a obtener un código RGB el cual se compara en una lista que contiene códigos de colores RGB más comunes junto con el nombre del color. Finalmente se procede a clasificar este color extraído en la lista utilizando el método de clasificación de distancia mínima euclidiana. Este proceso se muestra en la Figura 6.

Etapa 2

Retomando la Figura 4 nos enfocamos únicamente en el proceso de detección y reconocimiento de los caracteres alfa-numéricos que componen las placas. Este proceso se realiza mediante “OpenALPR”, el cual consiste en definir un umbral límite de caracteres que se aceptan para delimitar el tamaño de la letra, una segmentación de caracteres con el fin de reconocer cada uno por separado, por último, tenemos una serie de filtros de limpieza de caracteres. Como resultado obtenemos los caracteres alfa-numéricos que componen la placa y su respectivo porcentaje de clasificación. Este proceso se muestra en la Figura 7.

Finalmente, esta propuesta termina con la parte correspondiente a la página web, cuya arquitectura se muestra en la Figura 8.

La pagina web se encuentra disponible para su visualización en el enlace siguiente: <https://2019b001.webflow.io/>



Figura 7. Proceso de reconocimiento de placas

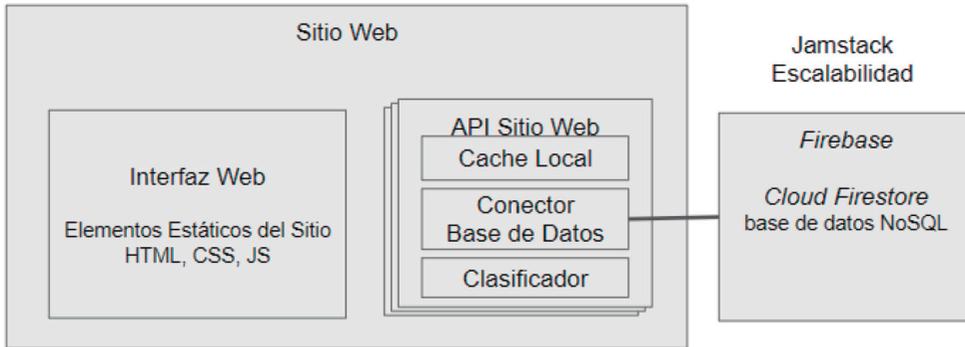


Figura 8. Arquitectura del sitio web

3. Resultados experimentales

Los resultados que se lograron al proponer diversas etapas de reconocimiento son favorables, permitiendo alcanzar porcentajes de un 99 % al momento del reconocer los automóviles. En la Figura 9 se puede observar una serie de graficas que contienen los índices de precisión al reconocer los tipos y modelos de las distintas marcas presentadas.

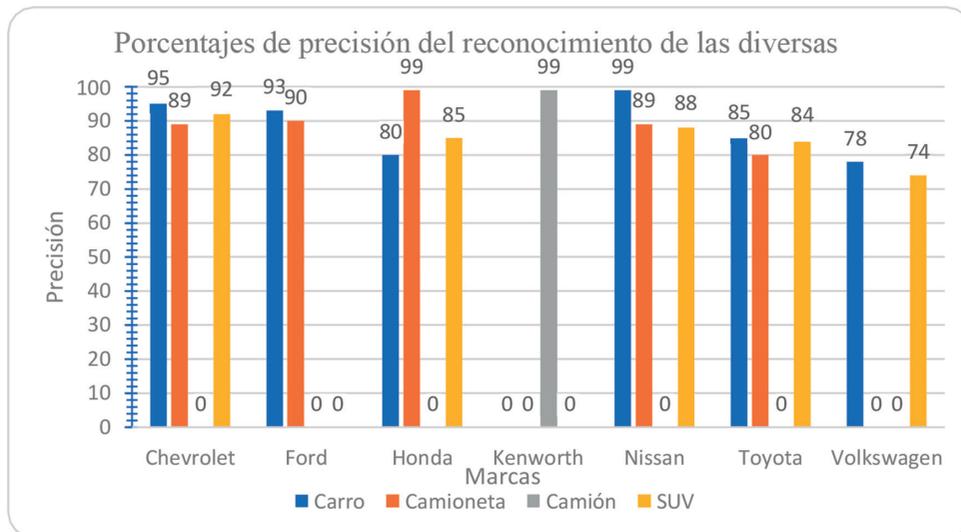


Figura 9. Precisión de reconocimiento

Características Reconocibles	Spectrico	Carnet.ai	*Eyedea	TT2019-B001
Tipo de Vehículo	X	X	✓	✓
Marca	✓	✓	✓	✓
Modelo	✓	✓	✓	✓
Color	✓	✓	✓	✓
Año	X	✓	✓	X
Placa	X	X	✓	✓
Porcentaje de Probabilidad	X	✓	✓	✓

Tabla 5 Competencia del mercado

Es importante mencionar que la marca que obtiene un menor índice de precisión es la de Volkswagen, esto se debe a que existe una similitud entre todos los modelos de su marca, siendo los únicos rasgos distintivos que existen entre sí, los bordes de los marcos de la ventana, lo cual no genera un buen índice discriminatorio como para ser tomado en cuenta.

En la Tabla 5 realizamos una comparativa de nuestro proyecto con otros trabajos existentes en el mercado, aquí cabe señalar que la mayoría de la competencia se encuentra en Estados Unidos. Esto se debe principalmente a que en México este tipo de proyectos no se encontró ningún estado del arte similar, la mayoría se limitan a reconocimiento de placas. La comparación la realizaremos con sistemas que toman las mismas características que nosotros para realizar un reconocimiento, estos son: “Spectrico” [10], “Carnet.ai” [11], “Eyedea” [12].

Aquí es importante señalar que, aunque Eyedea realiza la mayoría de las detecciones de características solo puede realizar esta detección si el vehículo cuenta con placa.

4. Discusión

Una parte importante para obtener resultados satisfactorios al momento de detectar un vehículo es un ángulo correcto en la toma de la imagen. Al momento de la



Figura 10. Ángulo correcto y erróneo en la toma de imagen

toma de la imagen, el ángulo de toma es muy importante ya que si lo tomamos con un ángulo entre 45° (picado) a 90° (cenital), se pierden muchos datos importantes de la imagen. En la Figura 10, se observa un ángulo que oscila entre los 0° hasta los 45°, los cuales permiten obtener más características del vehículo. En caso contrario, si tomamos una imagen desde un ángulo mayor se pierden características importantes que hacen que la red neuronal que entrenamos no sea capaz de identificar, ya que no cuenta con las características desde una vista superior del vehículo.

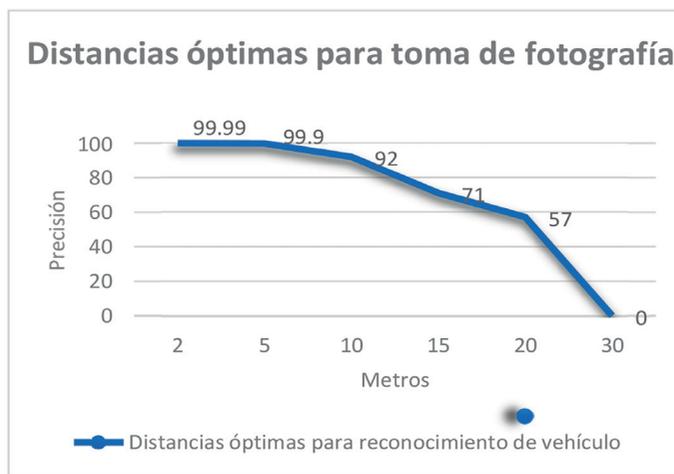


Gráfico 1. Precisión conforme a la distancia

Para el reconocimiento óptimo del vehículo, este tiene que cumplir con ciertas distancias en el momento de la toma de la imagen, para evitar un reconocimiento erróneo o simplemente no ser reconocido. La distancia mínima recomendada son 2 metros hasta los 30 metros, de ahí en adelante no se detectará el vehículo. Como se puede ver en el Gráfico 1, conforme el carro se aleja, el nivel de precisión de la red disminuye, ya que se puede apreciar que a una distancia de 2 metros su precisión es del 99.99 %, mientras que a la distancia de 30 metros la precisión es del 0 %, ya que no se logró detectar el vehículo. Esta característica se asemeja a la visión humana, ya que entre más distancia que tenemos entre el objeto a identificar menos características podemos extraer del mismo lo cual nos dificultara su identificación.

5. Conclusión y trabajos futuros

Se lograron identificar los vehículos que se encuentran en el índice de los más robados en la Ciudad de México, esto gracias a la especialización que se planteó al entrenar diversas redes neuronales. De la misma manera se logró identificar una red neuronal que nos proporcionaba mejores resultados y que se beneficiaba de la calidad del conjunto de imágenes que se recopilaron. Se realizaron análisis comparativos contra 3 sistemas que se encuentran en el mercado, permitiéndonos así identificar los diversos problemas que existen al momento de realizar una clasificación de vehículos.

Con respecto a trabajos a futuros, esta propuesta una contribución a la ciencia del reconocimiento de automóviles, ya que puede haber mejoras tales como: aumentar las marcas y modelos disponibles a reconocer. También sería recomendable contar con una base de datos más amplia y realizar más entrenamientos a las redes neuronales.

Mejorar la precisión en fotografías con poca luz(noche) es posible si ingresamos este tipo de imágenes en nuestro conjunto de entrenamiento. Existen modelos problemáticos en los que se tendría que buscar un rasgo más distintivo para lograr diferenciar estos modelos de vehículo.

Cabe hacer mención que esta propuesta de investigación se deriva del proyecto SIP:20196276.

Referencias

- [1] El informador, «Informador.mx,» 07 junio 2019. [En línea]. Disponible: <https://www.informador.mx/Recuperacion-de-autos-robados-se-duplican-en-los-ultimos-tres-anos-l201906070001.html>
- [2] Forbes Staff, «Forbes México,» 15 mayo 2019. [En línea]. Disponible: <https://www.forbes.com.mx/las-alcaldias-de-la-cdmx-con-mayor-robo-de-vehiculos/>
- [3] Expansión, «Expansion.mx,» 12 12 2018. [En línea]. Disponible: <https://expansion.mx/nacional/2018/12/12/el-2018-cierra-con-cifras-record-en-robo-de-autos-y-estos-son-los-favoritos>
- [4] PGJ, «Datos CDMX,» diciembre 2019. [En línea]. Disponible: <https://datos.cdmx.gob.mx/explore/embed/dataset/carpetas-de-investigacion-pgj-de-la-ciudad-de-mexico>
- [5] Darrenl, «labelImg,» 02 diciembre 2018. [En línea]. Disponible: <https://github.com/tzutalin/labelImg> [Último acceso: 09 01 2021].
- [6] Google, «Firebase helps you build,» 17 Diciembre 2020. [En línea]. Disponible: <https://firebase.google.com>
- [7] openalpr, «OpenALPR 2.3.0,» 17 julio 2016. [En línea]. Disponible: <https://github.com/openalpr/openalpr>
- [8] Webflow, «CDN versus Global CDN,» 02 2017. [En línea]. Disponible: <https://forum.webflow.com/t/cdn-versus-global-cdn/39127> [Último acceso: 11 01 2021].
- [9] Google, «¿Que es Colaboratory?,» 2019. [En línea]. Disponible: <https://colab.research.google.com/notebooks/intro.ipynb>
- [10] Spectrico, «CAR MAKE, MODEL AND COLOR RECOGNITION DEMO,» 2019-2020. [En línea]. Disponible: <http://spectrico.com/demo-car-mmr.html> [Último acceso: 11 01 2020].

- [11] Carnet, «Make / Model Recognition,» 2020. [En línea]. Disponible: <https://carnet.ai> [Último acceso: 11 01 2021].
- [12] Eyedea, «VCL Demo - MMR Make and Model Recognition,» 2020. [En línea]. Disponible: <https://cloud.eyedea.cz/api/VCL> [Último acceso: 11 01 2021].