

**UNIVERSIDAD PERUANA UNIÓN**  
FACULTAD DE INGENIERIA Y ARQUITECTURA  
Escuela Profesional de Ingeniería de Sistemas



**Redes neuronales convolucionales para la identificación de  
placas vehiculares**

Tesis para obtener el Título Profesional de Ingeniero de Sistemas

**Autores:**

José Antonio Ruiz Herrera  
Erick Daniel Zumaeta Diaz

**Asesor:**

Mtr.Cristian García-Estrella

Tarapoto, Noviembre 2024

## DECLARACIÓN JURADA DE ORIGINALIDAD DE TESIS

Yo Cristian Werner García Estrella, docente de la Facultad de Ingeniería y Arquitectura, Escuela Profesional de Ingeniería de Sistemas, de la Universidad Peruana Unión.

DECLARO:

Que la presente investigación titulada: **“REDES NEURONALES CONVOLUCIONALES PARA LA IDENTIFICACIÓN DE PLACAS VEHICULARES”** de los autores José Antonio Ruiz Herrera y Erick Daniel Zumaeta Díaz tiene un índice de similitud de **10 %** verificable en el informe del programa Turnitin, y fue realizada en la Universidad Peruana Unión bajo mi dirección.

En tal sentido asumo la responsabilidad que corresponde ante cualquier falsedad u omisión de los documentos como de la información aportada, firmo la presente declaración en la ciudad de Tarapoto, a los 12 días del mes de diciembre del año 2024



Cristian Werner García Estrella

ACTA DE SUSTENTACIÓN DE TESIS



En San Martín, Tarapoto, Morales, a 22 día(s) del mes de noviembre del año 2024 siendo las 11:20 horas, se reunieron los miembros del jurado en la Universidad Peruana Unión Campus Tarapoto, bajo la dirección del (de la) presidente(a): Mg. Danny Levano Rodriguez el (la) secretario(a): Mg. Joseph Cruz Rodriguez y los demás miembros: Mtra. Yngue Elizabeth Ramirez Pezo y el (la) asesor(a) Mg. Cristian Werner Garcia Estrella

con el propósito de administrar el acto académico de sustentación de la tesis titulado: Redes Neuronales convolucionales para la identificación de placas vehiculares

del(los) bachiller(es): a) Erick Daniel Zumaeta Diaz  
 b) José Antonio Ruiz Herrera  
 c) \_\_\_\_\_

conducente a la obtención del título profesional de: Ingeniero de sistemas  
(Denominación del Título Profesional)

El Presidente inició el acto académico de sustentación invitando al (a la) / a (los) (las) candidato(a)s hacer uso del tiempo determinado para su exposición. Concluida la exposición, el Presidente invitó a los demás miembros del jurado a efectuar las preguntas, y aclaraciones pertinentes, las cuales fueron absueltas por al (a la) / a (los) (las) candidato(a)s. Luego, se produjo un receso para las deliberaciones y la emisión del dictamen del jurado.

Posteriormente, el jurado procedió a dejar constancia escrita sobre la evaluación en la presente acta, con el dictamen siguiente:

Bachiller-(a): Erick Daniel Zumaeta Diaz

CALIFICACIÓN	ESCALAS			Mérito
	Vigesimal	Literal	Cualitativa	
<u>Aprobado</u>	<u>10</u>	<u>A-</u>	<u>Muy Bueno</u>	<u>Sobre Saliente</u>

Bachiller -(b): José Antonio Ruiz Herrera

CALIFICACIÓN	ESCALAS			Mérito
	Vigesimal	Literal	Cualitativa	
<u>Aprobado</u>	<u>10</u>	<u>A-</u>	<u>Muy Bueno</u>	<u>Sobre Saliente.</u>

Bachiller -(c): \_\_\_\_\_

CALIFICACIÓN	ESCALAS			Mérito
	Vigesimal	Literal	Cualitativa	

(\*) Ver parte posterior

Finalmente, el Presidente del jurado invitó al (a la) / a (los) (las) candidato(a)s a ponerse de pie, para recibir la evaluación final y concluir el acto académico de sustentación procediéndose a registrar las firmas respectivas.

[Firma]  
 Presidente/a

[Firma]  
 Secretario/a

[Firma]  
 Asesor/a

\_\_\_\_\_  
 Miembro

[Firma]  
 Miembro

[Firma]  
 Bachiller (a)

[Firma]  
 Bachiller (b)

\_\_\_\_\_  
 Bachiller (c)

**(\*) Tabla de Calificación**

CALIFICACIÓN	ESCALAS			Mérito
	Vigesimal	Literal	Cualitativa	
APROBADO	20	A+	Con nominación de Excelente	Excelencia
	19	A		
	18	A-	Con nominación de Muy Bueno	Sobresaliente
	17	B+		
	16	B	Con nominación de Bueno	Muy Bueno
	15	B-		
	14	C	Con nominación de Aceptable	Bueno
DESAPROBADO	Menos de 14	D	Con nominación de Deficiente	Insuficiente

# REDES NEURONALES CONVOLUCIONALES PARA LA IDENTIFICACIÓN DE PLACAS VEHICULARES

## CONVOLUTIONAL NEURAL NETWORKS FOR LICENSE PLATE IDENTIFICATION

José Antonio Ruiz Herrera<sup>1</sup>, Erick Daniel Zumaeta Diaz<sup>2</sup>, Cristian García-Estrella<sup>3</sup>

### Resumen

El uso de redes neuronales convolucionales para la identificación de placas vehiculares ha demostrado ser una solución frente a los crecientes niveles de inseguridad ciudadana. Los modelos YOLOv5, YOLOv8 y Detectron2 fueron evaluados para determinar su eficacia en la detección y reconocimiento de placas. Los resultados indicaron que YOLOv8 sobresale por su precisión y rapidez, seguido de cerca por YOLOv5, mientras que Detectron2, aunque más lento, mostró alta precisión y fiabilidad. Para el desarrollo de esta investigación, se utilizó la herramienta Colab para gestionar las redes neuronales y un dataset de 700 imágenes de vehículos, que fueron etiquetadas usando Roboflow. Los resultados mostraron una disminución significativa en las pérdidas de entrenamiento y validación, indicando una mejora continua en la capacidad de los modelos para identificar y localizar objetos con precisión. La implementación de estas tecnologías permitió una identificación eficiente de las placas vehiculares, facilitando la labor de las autoridades en la gestión de incidentes delictivos y accidentes. Los modelos propuestos ofrecen una base sólida para futuras mejoras. Se concluye que los modelos de redes neuronales convolucionales como YOLOv5, YOLOv8 y Detectron2 representan una herramienta eficaz para la identificación de placas vehiculares en entornos locales.

### Abstract

The use of convolutional neural networks for license plate identification has proven to be a solution to the increasing levels of citizen insecurity. The YOLOv5, YOLOv8 and Detectron2 models were evaluated to determine their effectiveness in license plate detection and recognition. The results indicated that YOLOv8 stands out for its accuracy and speed, followed closely by YOLOv5, while Detectron2, although slower, showed high accuracy and reliability. For the development of this research, the Colab tool was used to manage the neural networks and a dataset of 700 vehicle images, which were labeled using Roboflow. The results showed a significant decrease in training and validation losses, indicating a continuous improvement in the models' ability to accurately identify and localize objects. The implementation of these technologies enabled efficient identification of vehicle license plates, facilitating the work of authorities in the management of criminal incidents and accidents. The proposed models provide a solid basis for future improvements. It is concluded that convolutional neural network models such as YOLOv5, YOLOv8 and Detectron2 represent an effective tool for license plate identification in local environments. The optimization of these models and the integration of automated institutional interoperability systems could

---

<sup>1</sup> Facultad de Ingeniería. Universidad Peruana Unión, Perú. jose.ruiz@upeu.edu.pe, ORCID: 0000-0001-6516-6237

<sup>2</sup> Facultad de Ingeniería. Universidad Peruana Unión, Perú. erickzumaeta@upeu.edu.pe, ORCID: 0000-0001-9257-0577

<sup>3</sup> Facultad de Ingeniería de Sistemas e Informática. Universidad Nacional de San Martín, Perú. cgarcia@unsm.edu.pe, ORCID: 0000-0002-5687-8694  
Author for correspondence: jose.ruiz@upeu.edu.pe

La optimización de estos modelos y la integración de sistemas automatizados de interoperabilidad institucional podrían transformar significativamente la capacidad de respuesta ante incidentes en Tarapoto.

**Palabras clave:** detección, entrenamiento, modelos, objetos, optimización, reconocimiento

significantly transform the incident response capacity in Tarapoto.

**Keywords:** detection, training, modeling, object, optimization, recognition, recognition

# 1. Introducción

El reconocimiento de las placas vehiculares juega un papel importante en la asociación de eventos fortuitos sucedidos en la vida diaria, desde una falta leve hasta un hecho delictivo muy grave pueden involucrarse con este proceso [1]. En las grandes ciudades se han implementado tecnologías para generar un registro que permita esta identificación, muchas veces limitados por el bajo nivel de tecnología adquirida por los gobiernos regionales y locales [2], esta limitante es crucial al momento de la identificación y reconocimiento de placas, ya que muchos de estos hechos se producen con las unidades vehiculares en movimiento, resulta ser agravante si la vía donde recorren no reúne las condiciones de calidad de las grandes ciudades, por ejemplo, calles pavimentadas que permiten el regular recorrido de los mismos [3].

En las grandes ciudades de los países de sudamérica, existe esta tecnología implementada, los gobiernos regionales y locales invierten grandes sumas de dinero para contar con la mejor tecnología de videovigilancia, esto permite la identificación y reconocimiento de las placas vehiculares para diversos fines [4], es importante resaltar que esta infraestructura no previenen los hechos fortuitos desafortunados ni tampoco evitan un hecho delictivo, sin embargo, generan el registro necesario para que las autoridades tomen cartas en el asunto sobre esta problemática [5].

En Perú, los niveles de inseguridad ciudadana van en aumento y aunque se puede identificar y reconocer una placa vehicular, todavía existe el compromiso de la interoperabilidad de las instituciones, ya que los gobiernos locales cuentan con las consultas a los registros públicos [6], aunque esto no requiere mucho tiempo, sería de gran ayuda que esta interoperabilidad puede hacer de manera automatizada para acelerar los procesos para dar con los responsables de hechos que involucran a unidades vehiculares como medio para hechos delictivos.

En Tarapoto, existe un sistema de videovigilancia implementado en las principales calles de la ciudad, además, las empresas privadas y negocios poseen este mismo sistema de vigilancia, esto permite la toma de videos para determinar responsabilidades civiles o penales en el caso de sucesos que perjudican a la población [7]. Por su parte la Municipalidad Provincial de San Martín cuenta con una central donde se monitoreó la actividad de la ciudadanía durante las 24 horas del día, si es que sucede un hecho delictivo o accidente donde se utilice un vehículo motorizado, la central de seguridad ciudadana avisa inmediatamente al personal de patrullaje y a la Policía Nacional del Perú, con este sistema es posible identificar de manera rudimentaria a los propietarios de vehículos [8], sin embargo, se evidencia un ineficiente método para la identificación de placas vehiculares frente a supuestos hechos delictivos en el distrito de Tarapoto.

La primera causa de este problema es el Ineficiente proceso de identificación de placas vehiculares, debido a que el periodo que toma el respectivo reconocimiento de los vehículos motorizados no es el esperado, además, si bien es cierto, existe un procedimiento el cual faltaría su estandarización para la realidad de nuestra ciudad, esto produce que los casos de judicializados tomen más del tiempo promedio. La segunda causa es la inadecuada tecnología que se utiliza en los sistemas de video vigilancia, ya que utilizan cámaras que no poseen alta definición, esto retarda la identificación de los elementos de las placas vehiculares, registrándose errores en el momento de dar parte a las autoridades. La última causa, es la inadecuada capacitación del personal de seguridad ciudadana para identificar estos elementos mencionados, esto genera retraso en la gestión para el registro de hechos delictivos con referencia a accidentes o a robos a


la ciudadanía. Finalmente, estos efectos generan altos niveles de injusticia para los ciudadanos que sufren estos hechos indeseados en la ciudad de Tarapoto.

La hipótesis de investigación las redes neuronales convolucionales influyen positivamente en la identificación de placas vehiculares en el distrito de Tarapoto, 2023


Los resultados más resaltantes establecen que los modelos YOLOv5, YOLOv8 y Detectron2 mostraron resultados robustos en la tarea de detección de placas vehiculares. YOLOv8 se destacó por su alta precisión y rapidez de inferencia, seguido de cerca por YOLOv5, que también mostró una gran eficiencia y precisión. Detectron2, aunque menos rápido, proporcionó resultados precisos y fiables, haciendo que cada uno de estos modelos sea adecuado para diferentes aplicaciones dependiendo de los requisitos específicos de precisión y velocidad.

## 2. Materiales y Métodos

Para el desarrollo de la presente investigación se utilizó la herramienta Colab para la gestión de las redes neuronales convolucionales (CNN) y un dataset de 700 imágenes que contenían tomas fotográficas de vehículos como autos, motocicletas y minivans (Figura 1), luego estas imágenes fueron etiquetadas para un mejor trabajo para las CNN [9], en este proceso se utilizó la herramienta Roboflow. Tanto para las imágenes como para sus etiquetas fue necesario crear los repositorios de entrenamiento, validación y prueba de las CNN (Figura 2), para el cual se utilizaron los algoritmos de YOLOv5, YOLOv8 y Detectron que son especializados para el reconocimiento de objetos en imágenes y vídeos con la finalidad de determinar cuál se utilizaría para la identificación de placas vehiculares [10].



**Figura 1.** Dataset de vehículos



**Figura 2.** Estructura de archivos del dataset

Para el caso de YOLOv5, YOLOv8 y Detectron 2, se clonó el repositorio correspondiente desde GitHub y se instalaron las bibliotecas y herramientas especificadas, luego se subió el dataset a Colab donde se encontraba el código correspondiente en el lenguaje de programación Python 3.11, se realizó el proceso de entrenamiento, validación y prueba de las imágenes.

### 3. Resultados y discusión

El entrenamiento del modelo YOLOv5 se realizó utilizando un dataset estructurado en Roboflow y el entorno de Google Colab con GPU. El dataset se dividió en imágenes y etiquetas para entrenamiento y validación. La configuración del entorno incluyó la clonación del repositorio YOLOv5 y la instalación de las dependencias necesarias. El archivo custom.yaml se utilizó para definir los directorios de entrenamiento y validación, así como las clases de objetos [11].

En el entrenamiento, en cuanto a la precisión media (mAP) el modelo YOLOv5 alcanzó una del 92% en el conjunto de validación, lo que demuestra una alta precisión en la detección de placas vehiculares [12].

La pérdida asociada con la detección de objetos disminuyó significativamente a lo largo del entrenamiento, estabilizándose en 0.2, indicando una mejora en la capacidad del modelo para identificar objetos relevantes.

La precisión en la localización de las placas mejoró con el progreso del entrenamiento, alcanzando un promedio del 87% en las últimas épocas, lo que sugiere una buena capacidad del modelo para determinar la posición exacta de las placas [13].


El modelo YOLOv5 mostró un tiempo de inferencia rápido, con un promedio de 0.01 segundos por imagen, adecuado para aplicaciones en tiempo real que requieren detección rápida

y eficiente [5]. Por otra parte, durante el entrenamiento, se registraron valores de precisión (Precision) y recuperación (Recall) con mejoras constantes, alcanzando valores de precisión de hasta 96% y de recuperación del 95.2% en las últimas épocas, con un F1-Score de 95.5%, reflejando un equilibrio óptimo entre precisión y recuperación (Tabla 1).

**Tabla 1.** Resultados de YOLOv5


Epochs	Precision	Recall	F1-Score
0-19	0.809634	0.8248805	0.8171861
20-39	0.941887	0.938165	0.9400223
40-59	0.9363915	0.930701	0.9335376
60-79	0.9522445	0.939849	0.9460061
80-99	0.9485315	0.9509995	0.9497639
100-119	0.9515005	0.9465515	0.9490195
120-139	0.952343	0.9396995	0.945979
140-159	0.963102	0.945846	0.954396
160-179	0.960351	0.9499435	0.9551189
<b>180-199</b>	<b>0.95892</b>	<b>0.952098</b>	<b>0.9554968</b>

A su vez, la disminución constante en las pérdidas de entrenamiento y validación sugiere que el modelo está aprendiendo de manera efectiva y generalizando bien a datos no vistos. La alta precisión y recuperación indican que YOLOv5 es capaz de detectar placas con alta fiabilidad, minimizando tanto falsos positivos como falsos negativos [14].



**Figura 3.** Pérdidas del entrenamiento y la validez de YOLOv5

En la Figura 3 se muestra una tendencia general de disminución en ambas métricas de pérdida (para entrenamiento y validación), lo que es indicativo de un proceso de entrenamiento exitoso. La convergencia de las pérdidas sugiere que el modelo está aprendiendo a detectar y localizar objetos de manera más precisa y consistente a lo largo del tiempo. La estabilización de las curvas hacia el final del entrenamiento también es una señal positiva de que el modelo no está sobrentrenándose y mantiene un buen equilibrio entre precisión y generalización [15].



**Figura 4.** Pérdidas de clasificación del entrenamiento, validez y precisión media de YOLOv5

La Figura 4 indica un proceso de entrenamiento exitoso y una buena generalización en datos de validación. Las pérdidas de clasificación disminuyen tanto en el entrenamiento como en la validación, aunque con más variabilidad en la validación, lo que es normal y esperado. Las métricas de precisión y recall muestran altos valores estables, sugiriendo que el modelo es efectivo en identificar y clasificar objetos correctamente. El mAP en ambos umbrales muestra que el modelo es preciso y robusto, capaz de detectar objetos de manera confiable con diferentes niveles de superposición [16]

Estos resultados indican un buen desempeño en la identificación de placas vehiculares, con una alta tasa de precisión y una razonable capacidad de recuperación de objetos.

Para el caso de YOLOv8, el entrenamiento del modelo se realizó utilizando la biblioteca Ultralytics, lo que simplificó el proceso de configuración y gestión de dependencias. El dataset, estructurado mediante Roboflow, se dividió en conjuntos de entrenamiento y validación, y se configuró utilizando un archivo custom.yaml específico para YOLOv8 [17].

El modelo YOLOv8 alcanzó una mAP del 94% en el conjunto de validación, superando ligeramente a YOLOv5 y demostrando una alta capacidad de detección. La pérdida asociada con la clasificación de objetos se redujo notablemente, alcanzando valores mínimos de 0.15, lo que sugiere una mejora en la diferenciación de objetos.

La precisión en la localización de placas mostró una mejora con un promedio del 89%, indicando una alta capacidad para determinar la posición exacta de las placas vehiculares.


YOLOv8 mostró un tiempo de inferencia aún más rápido que YOLOv5, con un promedio de 0.008 segundos por imagen, haciéndolo altamente eficiente para aplicaciones en tiempo real.

Durante el entrenamiento, YOLOv8 logró valores de precisión y recuperación destacables, con precisiones alcanzando hasta 95.8% y recuperaciones de 91.5%, resultando en un F1-Score de 93.7%.

**Tabla 2.** Resultados de YOLOv8


Epochs	Precision	Recall	F1-Score
0-19	0.685129	0.651777	0.668453
20-39	0.9220975	0.8658025	0.89395
40-59	0.9365785	0.8923935	0.914486
60-79	0.9489035	0.8997885	0.924346
80-99	0.9385315	0.9028645	0.920698
100-119	0.9468885	0.915515	0.93120175
120-139	0.9523775	0.9124185	0.932398
140-159	0.949913	0.9101045	0.93000875
160-179	0.955846	0.914199	0.9350225
<b>180-199</b>	<b>0.958998</b>	<b>0.9154795</b>	<b>0.93723875</b>

Se observaron dos advertencias significativas durante el entrenamiento. La primera indicaba una discrepancia en el recuento de cajas y segmentos, que se resolvió utilizando solo las cajas para evitar inconsistencias. La segunda advertencia provenía de Albumentations, informando sobre la aplicación de transformaciones aleatorias con una probabilidad muy baja, lo cual no afectó significativamente el rendimiento del modelo.



**Figura 5.** Pérdidas del entrenamiento y la validez de YOLOv8

La Figura 5 muestra una tendencia general de disminución en las métricas de pérdida tanto para entrenamiento como para validación, lo que indica un proceso de entrenamiento exitoso. Las pérdidas de las cajas delimitadoras y de clasificación disminuyen de manera significativa, lo que sugiere que el modelo está mejorando en la identificación y localización de objetos a lo largo del tiempo. Sin embargo, la variabilidad observada en las pérdidas de validación sugiere que el modelo podría beneficiarse de un mayor ajuste de los hiperparámetros o de una mayor cantidad de datos de entrenamiento para mejorar su capacidad de generalización.



**Figura 6.** Pérdidas de clasificación del entrenamiento, validez y precisión media de YOLOv8

La Figura 6 sugiere que el modelo está aprendiendo de manera efectiva y rindiendo bien tanto en los conjuntos de entrenamiento como de validación. La pérdida está disminuyendo y las métricas clave, como precisión, recuerdo y mAP, están aumentando y estabilizándose en valores altos.

El modelo YOLOv8 demostró ser robusto y eficiente, mostrando mejoras en todas las métricas clave en comparación con YOLOv5, lo que lo hace ideal para aplicaciones que requieren alta precisión y velocidad.

Estos incrementos en mAP y precisión sugieren una mayor efectividad en la detección y localización de placas vehiculares, debido posiblemente a las mejoras en la arquitectura del modelo y la optimización del entrenamiento.

El modelo Faster R-CNN basado en la arquitectura X-101-32x8d FPN fue entrenado utilizando Detectron2 para detectar placas vehiculares. Se ajustaron parámetros como el tamaño del lote, la tasa de aprendizaje y el número de iteraciones para optimizar el rendimiento del modelo. La


configuración del entrenamiento incluyó un tamaño de lote de 2 imágenes por iteración, una tasa de aprendizaje base de 0.001 y un máximo de 5875 iteraciones.

La exactitud de clasificación mostró una mejora constante, alcanzando una exactitud promedio del 99.3% en las iteraciones finales, lo que indica una alta capacidad para distinguir entre placas y fondo.

La exactitud para la detección de placas específicas también mostró un buen rendimiento, con un promedio del 99.7%.


Epochs	Precision	Recall
0-599	0,959895833	0,840581955
600-1179	0,984509698	0,981115006
1180- 1779	0,98828125	0,988432139
1780- 2339	0,990164621	0,99220186
2340- 2939	0,991927083	0,991663517
2940- 3539	0,992317708	0,993900372
3540- 4119	0,993130388	0,997169236
4120- 4699	0,993534483	0,995529595
4700- 5279	0,99299569	0,9970776
<b>5280- 5874</b>	<b>0,993229167</b>	<b>0,997076089</b>

La pérdida total del modelo disminuyó progresivamente, comenzando en 1.5 y reduciéndose a 0.3 al final del entrenamiento, lo que sugiere que el modelo está aprendiendo de manera efectiva.



**Figura 7.** Pérdida total de Detectron2

La pérdida de regresión de caja mide la precisión en la localización de las cajas delimitadoras, mostró una reducción significativa, indicando una mejora en la precisión espacial de las detecciones.



**Figura 8.** Pérdida de regresión de caja de Detectron2

La pérdida asociada con la clasificación de objetos se redujo de manera constante, alcanzando valores mínimos en las últimas iteraciones. El modelo logró reducir el número de falsos negativos a un promedio del 5%, mejorando la capacidad del modelo para detectar todas las placas presentes en las imágenes.

Detectron2 mostró una alta capacidad para la detección precisa de placas vehiculares, con métricas que indican una buena generalización y un bajo número de falsos negativos.




**Figura 9.** Identificación de placas en motocicletas

A pesar de que Detectron2 no es tan rápido como YOLOv5 o YOLOv8, su precisión en la clasificación y localización lo hace una herramienta valiosa para aplicaciones donde la exactitud es crucial, además, Detectron2 es igualmente efectivo para la tarea de identificación de placas vehiculares, sin embargo, el proceso de entrenamiento fue más complejo y requirió una configuración más detallada de los hiperparámetros.



**Figura 10.** Identificación de placas en automóviles



**Figura 10.** Identificación de placa en movimiento

Los modelos YOLOv5, YOLOv8 y Detectron2 mostraron resultados robustos en la tarea de detección de placas vehiculares. YOLOv8 se destacó por su alta precisión y rapidez de inferencia, seguido de cerca por YOLOv5, que también mostró una gran eficiencia y precisión. Detectron2, aunque menos rápido, proporcionó resultados precisos y fiables, haciendo que cada uno de estos modelos sea adecuado para diferentes aplicaciones dependiendo de los requisitos específicos de precisión y velocidad.

La comparación de los tres modelos (YOLOv5, YOLOv8 y Detectron2) revela que todos ellos pueden ser utilizados eficazmente para la identificación de placas vehiculares. YOLOv8 mostró un rendimiento ligeramente superior, lo cual puede ser atribuido a las mejoras en su arquitectura y la facilidad de configuración proporcionada por Ultralytics. Detectron2, aunque complejo en su configuración, también presentó resultados competitivos, destacándose por su flexibilidad y capacidad de personalización.

Estos resultados sugieren que, dependiendo de los recursos disponibles y la facilidad de uso, cualquiera de los tres modelos puede ser una opción viable para aplicaciones de identificación de placas vehiculares. Los futuros trabajos deberían enfocarse en optimizar aún más los parámetros de entrenamiento y explorar combinaciones de estos modelos para mejorar la precisión y eficiencia de detección.

#### **4. Conclusiones**

En este estudio, se investigó el uso de redes neuronales convolucionales (CNN) para la identificación de placas vehiculares en el distrito de Tarapoto, Perú, utilizando modelos YOLOv5, YOLOv8 y Detectron2. Los resultados obtenidos demuestran que todos los modelos son efectivos en la tarea de detección, con YOLOv8 destacándose por su alta precisión y rapidez de inferencia, seguido de cerca por YOLOv5. Detectron2, aunque menos rápido, proporcionó resultados precisos y fiables, lo que lo hace adecuado para aplicaciones donde la exactitud es crucial.

Durante el entrenamiento del modelo YOLOv5, se alcanzó una precisión media (mAP) del 92% en el conjunto de validación, con una pérdida de detección de objetos que disminuyó significativamente hasta estabilizarse en 0.2. La precisión en la localización de placas mejoró a lo largo del entrenamiento, alcanzando un promedio del 87% en las últimas épocas, y el tiempo de inferencia fue rápido, con un promedio de 0.01 segundos por imagen. Estos resultados sugieren que YOLOv5 es adecuado para aplicaciones en tiempo real que requieren detección rápida y eficiente.

Por otra parte, el modelo Detectron2 mostró una alta capacidad para la detección precisa de placas vehiculares, con una exactitud promedio del 99.3% en la clasificación y del 99.7% en la detección de placas específicas. Aunque no es tan rápido como los modelos YOLO, su precisión en la clasificación y localización lo hace una herramienta valiosa para aplicaciones donde la exactitud es crucial. Detectron2 también es efectivo para la identificación de placas vehiculares, aunque el proceso de entrenamiento fue más complejo y requirió una configuración más detallada de los hiperparámetros.

Finalmente, los modelos YOLOv5, YOLOv8 y Detectron2 demostraron ser robustos y eficientes en la tarea de detección de placas vehiculares. Dependiendo de los recursos disponibles y los requisitos específicos de precisión y velocidad, cualquiera de estos modelos puede ser una opción viable para aplicaciones de identificación de placas vehiculares. Los futuros trabajos deberían enfocarse en optimizar aún más los parámetros de entrenamiento y explorar combinaciones de estos modelos para mejorar la precisión y eficiencia de detección.

## References

- [1] T. de la Rosa Martín, «Sistema de identificación de placas automotrices para la Universidad Metropolitana de Ecuador», *Universidad y Sociedad*, vol. 13, n.º 1, Art. n.º 1, feb. 2021.
- [2] I. Shafi *et al.*, «License plate identification and recognition in a non-standard environment using neural pattern matching», *Complex Intell. Syst.*, vol. 8, n.º 5, pp. 3627-3639, oct. 2022, doi: 10.1007/s40747-021-00419-5.
- [3] C. Y. Dorado Ceballos, D. M. Sandoval Malquín, y D. P. Rodríguez Guzmán, «Tecnología de visión artificial para disminuir accidentes terrestres de unidades de la cooperativa San Cristóbal.», *Dilemas contemporáneos: Educación, Política y Valores*, sep. 2021, doi: 10.46377/dilemas.v9i1.2889.
- [4] D. M. F. Izidio, A. P. A. Ferreira, H. R. Medeiros, y E. N. da S. Barros, «An embedded automatic license plate recognition system using deep learning», *Des Autom Embed Syst*, vol. 24, n.º 1, pp. 23-43, mar. 2020, doi: 10.1007/s10617-019-09230-5.
- [5] C. González-Cruz *et al.*, «Uso del aprendizaje automático en el diagnóstico del melanoma. Limitaciones por superar», *Actas Dermo-Sifiliográficas*, vol. 111, n.º 4, pp. 313-316, may 2020, doi: 10.1016/j.ad.2019.09.002.
- [6] I. V. Pustokhina *et al.*, «Automatic Vehicle License Plate Recognition Using Optimal K-Means With Convolutional Neural Network for Intelligent Transportation Systems», *IEEE Access*, vol. 8, pp. 92907-92917, 2020, doi: 10.1109/ACCESS.2020.2993008.
- [7] M. A. Rafique, W. Pedrycz, y M. Jeon, «Vehicle license plate detection using region-based convolutional neural networks», *Soft Comput*, vol. 22, n.º 19, pp. 6429-6440, oct. 2018, doi: 10.1007/s00500-017-2696-2.
- [8] X. Zhang, N. Gu, H. Ye, y C. Lin, «Vehicle license plate detection and recognition using deep neural networks and generative adversarial networks», *JEI*, vol. 27, n.º 4, p. 043056, ago. 2018, doi: 10.1117/1.JEI.27.4.043056.
- [9] W. H. Curioso y M. J. Brunette, «Inteligencia artificial e innovación para optimizar el proceso de diagnóstico de la tuberculosis», *Revista Peruana de Medicina Experimental y Salud Pública*, vol. 37, n.º 3, pp. 554-558, jul. 2020, doi: 10.17843/rpmesp.2020.373.5585.
- [10] C. Aracena, F. Villena, F. Arias, y J. Dunstan, «Aplicaciones de aprendizaje automático en salud», *Revista Médica Clínica Las Condes*, vol. 33, n.º 6, pp. 568-575, nov. 2022, doi: 10.1016/j.rmcl.2022.10.001.
- [11] J. F. Cortes Zarta, Y. A. Giraldo Tique, y C. F. Vergara Ramírez, «Red neuronal convolucional para la percepción espacial del robot InMoov a través de visión estereoscópica como tecnología de asistencia», *Enfoque UTE*, vol. 12, n.º 4, pp. 88-104, dic. 2021, doi: 10.29019/enfoqueute.776.
- [12] M. Guerra-Londono, L. Castano-Londono, C. Alzate-Anzola, D. Marquez-Viloria, y R. Velasquez-Velez, «Análisis de desempeño de capas de CNN para arquitecturas heterogéneas basadas en FPGAs usando HLS», *Ingeniería*, vol. 26, n.º 1, pp. 62-76, abr. 2021, doi: 10.14483/23448393.15634.

- [13] J. Teuwen y N. Moriakov, «Chapter 20 - Convolutional neural networks», en *Handbook of Medical Image Computing and Computer Assisted Intervention*, S. K. Zhou, D. Rueckert, y G. Fichtinger, Eds., en The Elsevier and MICCAI Society Book Series. , Academic Press, 2020, pp. 481-501. doi: 10.1016/B978-0-12-816176-0.00025-9.
- [14] J. M. Pineda, «Modelos predictivos en salud basados en aprendizaje de maquina (machine learning)», *Revista Médica Clínica Las Condes*, vol. 33, n.º 6, pp. 583-590, nov. 2022, doi: 10.1016/j.rmclc.2022.11.002.
- [15] D. Pérez-Aguilar, R. Risco-Ramos, y L. Casaverde-Pacherrez, «Transfer learning en la clasificación binaria de imágenes térmicas», *Ingenius. Revista de Ciencia y Tecnología*, n.º 26, pp. 71-86, dic. 2021, doi: 10.17163/ings.n26.2021.07.
- [16] H. F. Mendoza Jurado, «Modelos de redes neuronales artificiales, como sustento evaluativo al crecimiento pedagógico virtual en Educación Superior», *Educación Superior*, vol. 7, n.º 2, pp. 25-36, sep. 2020.
- [17] M. Guerra-Londono, L. Castano-Londono, C. Alzate-Anzola, D. Marquez-Viloria, y R. Velasquez-Velez, «Análisis de desempeño de capas de CNN para arquitecturas heterogéneas basadas en FPGAs usando HLS», *Ingeniería*, vol. 26, n.º 1, pp. 62-76, abr. 2021, doi: 10.14483/23448393.15634.