



Universidad
Nacional
de Loja

Universidad Nacional de Loja

Facultad de la Energía, las Industrias y los Recursos

Naturales No Renovables

Carrera de Ingeniería en Mecánica Automotriz

Determinación del Flujo Vehicular en Una Zona Crítica de la Ciudad
de Loja Aplicando YOLOv5.

Trabajo de Titulación, previo a la
obtención del título de Ingeniero
Mecánico Automotriz.

AUTOR:

Edwin Fernando Sarango Tacuri

DIRECTORA:

Ing. Génesis Jahel Vásquez Rodríguez Mg. Sc.

Loja – Ecuador

2025

Certificación

Loja, 13 de enero de 2025

Ing. Génesis Jahel Vásquez Rodríguez Mg. Sc.

DIRECTORA DEL TRABAJO DE TITULACIÓN

CERTIFICO:

Que he revisado y orientado todo el proceso de la elaboración del Trabajo de Titulación denominado: **Determinación del Flujo Vehicular en Una Zona Crítica de la Ciudad de Loja Aplicando YOLOv5**, previo a la obtención del título de **Ingeniero Mecánico Automotriz**, de la autoría del estudiante **Edwin Fernando Sarango Tacuri**, con cédula de identidad Nro. **1900541820**, una vez que el trabajo cumple con todos los requisitos exigidos por la Universidad Nacional de Loja para el efecto, autorizo la presentación para la respectiva sustentación y defensa.

Ing. Génesis Jahel Vásquez Rodríguez, Mg. Sc.

DIRECTORA DEL TRABAJO DE TITULACIÓN

Autoría

Yo, **Edwin Fernando Sarango Tacuri**, declaro ser autor del presente Trabajo de Titulación y eximo expresamente a la Universidad Nacional de Loja y a sus representantes jurídicos de posibles reclamos y acciones legales, por el contenido del mismo. Adicionalmente acepto y autorizo a la Universidad Nacional de Loja la publicación de mi Trabajo de Titulación en el Repositorio Digital Institucional – Biblioteca Virtual.

Firma:

Cédula de Identidad: 1900541820

Fecha: 13 de enero de 2025

Correo electrónico: edwin.f.sarango@unl.edu.ec / edwinsarango722@gmail.com

Teléfono: 0986529392

Carta de autorización por parte del autor, para consulta, reproducción parcial o total y/o publicación electrónica del texto completo, del trabajo de titulación.

Yo, **Edwin Fernando Sarango Tacuri** declaro ser autor del Trabajo de Titulación denominado: **Determinación del flujo vehicular en una zona crítica de la ciudad de Loja aplicando Yolov5**, como requisito para optar el título de **Ingeniero Mecánico Automotriz**, autorizo al sistema Bibliotecario de la Universidad Nacional de Loja para que con fines académicos muestre la producción intelectual de la Universidad, a través de la visibilidad de su contenido de la siguiente manera en el Repositorio Institucional.

Los usuarios pueden consultar el contenido de este trabajo en el Repositorio Institucional, en las redes de información del país y del exterior con las cuales tenga convenio la Universidad.

La Universidad Nacional de Loja, no se responsabiliza por el plagio o copia del Trabajo de Titulación que realice un tercero.

Para constancia de esta autorización, suscribo, en la ciudad de Loja, a los trece días del mes de enero del dos mil veinticinco.

Firma:

Autor: Edwin Fernando Sarango Tacuri

Cédula: 1900541820

Dirección: Loja-Ecuador (Barrio Época: Calle Brasil)

Correo electrónico: edwin.f.sarango@unl.edu.ec

Teléfono: 0986529392 / 07-2300596

DATOS COMPLEMENTARIOS:

Directora del Trabajo de Titulación: Ing. Génesis Jahel Vásquez Rodríguez, Mg. Sc.

Dedicatoria

Con inmensa gratitud, dedico este trabajo a mi madre Rosa, pilar fundamental en mi vida, a mis abuelos Leonardo y Mercedes que brindaron su apoyo incondicional y nunca dejaron de creer en mí. A mis primos pequeños, Jeanpierre, Sofía, Ivania, Victoria, Alejandro e Isaac por llenar mi vida de alegría mostrándoles que con persistencia se pueden lograr las metas que te propongas. También, a mis tíos por sus consejos y ayuda en cada etapa de mi vida. A los amigos que me deja la universidad, que llenaron de experiencias inolvidables estos últimos años; y a todas las personas importantes que dejaron huella en mi camino; maestros que me inspiraron y mentores que me guiaron. Este logro es para todos ustedes.

Edwin Fernando Sarango Tacuri

Agradecimiento.

Agradezco profundamente a Dios por guiarme en este camino. A la Universidad Nacional de Loja, por brindarme la oportunidad de crecer académicamente. A los docentes de la carrera de Ingeniería Mecánica Automotriz por compartir su sabiduría y experiencia. A los ingenieros que fueron mentores a la hora de mostrar y enseñar el arte de la mecánica. Y a mi tutora de tesis la Ing. Génesis Jahel Vásquez Rodríguez, por su invaluable apoyo y orientación en este proceso. Gracias a todos por contribuir a mi formación y éxito.

Edwin Fernando Sarango Tacuri

Contenido

Portada	i
Certificación	ii
Autoría	iii
Carta de autorización	iv
Dedicatoria	v
Agradecimiento	vi
Índice de contenidos	vii
Índice de tablas	x
Índice de figuras.....	xi
Índice de anexos.....	xiii
1. Título.....	1
2. Resumen.....	2
Abstract.....	3
3. Introducción	4
4. Marco teórico	6
4.1 Flujo vehicular.....	6
4.2 Elementos del flujo de Tránsito.....	7
4.2.1 El flujo (q)	7
4.2.2 La densidad (k).....	7
4.2.3 La velocidad (u):	7
4.2.4 Velocidad media en el tiempo (u_t)	7
4.3 Variables relacionadas con el flujo.....	8
4.3.1 Intervalo simple entre vehículos consecutivos (h_i);	8
4.3.2 Intervalo promedio entre vehículos (h);.....	8
4.4 Congestionamiento vehicular	9
4.5 Redes neuronales convolucionales.....	9
4.6 YOLOv5.....	10

4.7	Capas convolucionales de YOLOv5	13
4.8	Métricas de YOLOv5	14
4.9	Investigaciones relacionadas	15
5.	Metodología	18
5.1	Selección de la zona de estudio.....	18
5.2	Obtención del conjunto de datos.	20
5.2.1	Captación de imágenes.....	20
5.2.2	Instrumentos para la captación de imágenes.....	21
5.2.3	Etiquetado de la base de datos.....	24
5.2.4	Clasificación de las etiquetas.	26
5.2.5	Creación de la base de datos.	27
5.2.6	Aumento de datos.....	28
5.3	Configuración de parámetros y entrenamiento del modelo.	29
5.3.1	Instalación de YOLOv5.....	29
5.3.2	Elaboración del archivo .yaml.....	30
5.3.3	Entrenamiento con YOLOv5.....	30
5.4	Evaluación del modelo entrenado.	33
5.4.1	Parámetros para la detección vehicular.	33
5.4.2	Puesta a prueba del modelo.....	33
5.5	Proceso de obtención del flujo vehicular con YOLOv5.....	35
5.5.1	Creación del script principal	35
5.5.2	Scripts auxiliares	36
5.5.3	Cálculo del flujo vehicular	37
5.5.4	Síntesis de la obtención del flujo vehicular.....	38
6.	Resultados	39
6.1	Conjunto de datos recopilados.	39
6.1.1	Bases de datos obtenidas.....	39

6.1.2	Base de datos etiquetada.	42
6.2	Métricas producto de los entrenamientos con YOLOv5	43
6.2.1	Conjunto de datos etiquetados.....	43
6.2.2	Pérdidas en los procesos de entrenamiento y validación.	44
6.2.3	Matriz de confusión.....	45
6.2.4	Precisión obtenida.	46
6.2.5	Recall.....	47
6.2.6	Relación entre la precisión y recall	48
6.2.7	Curva F1	49
6.2.8	Batch del proceso de entrenamiento.....	50
6.3	Desempeño del modelo entrenado en nuevas imágenes.	51
6.4	Determinar el flujo vehicular.....	52
6.4.1	Conteo de vehículos	52
6.4.2	Tiempo de análisis aplicados.....	53
6.4.3	Flujo vehicular obtenido.....	53
6.4.4	Efectividad del sistema de detección	55
7.	Discusión.....	58
8.	Conclusiones	59
9.	Recomendaciones	60
10.	Bibliografía	61
11.	Anexos	66

Índice de tablas:

Tabla 1. <i>Características de cámara Sony IMX766 vs ESP32-Cam</i>	22
Tabla 2. <i>Características de Dron DJI Phantom 4 Pro V2.0</i>	23
Tabla 3. <i>Hiperparámetros Usados en los Entrenamientos.</i>	31
Tabla 4. <i>Cantidad de Imágenes Obtenidas en las Semanas Impares del Mes.</i>	39
Tabla 5. <i>Cantidad de Imágenes Obtenidas en las Semanas Pares del Mes.</i>	40
Tabla 6. <i>Cantidad de Imágenes Obtenidas en los Feriados del Mes.</i>	40
Tabla 7. <i>Cantidad Total de Imágenes Obtenidas en el Mes.</i>	41
Tabla 8. <i>Reducción de la Base de Datos Principal.</i>	41
Tabla 9. <i>Reducción de la Base de Datos Secundaria a Base de Datos Final.</i>	42
Tabla 10. <i>Aumento de la Base de Datos.</i>	42
Tabla 11. <i>Vehículos Contabilizados</i>	52
Tabla 12. <i>Captación del Tiempo.</i>	53
Tabla 13. <i>Resultados del Flujo Vehicular de Manera Manual.</i>	54
Tabla 14. <i>Resultados del Flujo Vehicular Aplicando Yolov5.</i>	54
Tabla 15. <i>Cálculo de la Eficacia del Sistema con Yolov5, en Segundos.</i>	55
Tabla 16. <i>Cálculo de la Eficacia del Sistema con Yolov5, en Minutos.</i>	56

Índice de figuras:

Figura 1. <i>Intervalos entre Vehículos.</i>	8
Figura 2. <i>Benchmark de Yolov5</i>	11
Figura 3. <i>Diagrama del Modelo de Red Yolov5.</i>	12
Figura 4. <i>Esquema de la Arquitectura de la Red Neuronal</i>	14
Figura 5. <i>Ubicación de la Zona Analizada.</i>	19
Figura 6. <i>Fotografía del Tránsito Captada con Dron</i>	20
Figura 7. <i>Diagrama de Flujo para Obtención del Conjunto de Datos.</i>	21
Figura 8. <i>Comparativa de Cámaras para la Captación de Datos.</i>	22
Figura 9. <i>Dron DJI Phantom 4 Pro V2.0</i>	23
Figura 10. <i>Proceso para Iniciar el Etiquetado del Conjunto de Datos.</i>	24
Figura 11. <i>Interfaz de Roboflow con una Imagen Background.</i>	25
Figura 12. <i>Función de Mark Unannotated en Roboflow.</i>	25
Figura 13. <i>Clasificación de Etiquetas en Roboflow.</i>	26
Figura 14. <i>Etiquetado de Vehículos y Selección de Tipo de Etiqueta.</i>	27
Figura 15. <i>Estructura de las Imágenes con su Correspondiente Etiqueta.</i>	27
Figura 16. <i>Diagrama del Proceso de Instalación de Yolov5 Mediante el Cmd (Command Prompt)</i>	29
Figura 17. <i>Contenido del archivo VL2024.yaml</i>	30
Figura 18. <i>Diagrama de Organización para Entrenamiento en Yolov5.</i>	31
Figura 19. <i>Diagrama de Flujo del Entrenamiento en Yolov5.</i>	32
Figura 20. <i>Diagrama de Inicio a una Detección con Yolov5.</i>	33
Figura 21. <i>Proceso de Detección en Yolov5.</i>	34
Figura 22. <i>Frame de la Zona de Interés (ROI) con la Línea Contabilizadora.</i>	36
Figura 23. <i>Resumen del Proceso para Obtener el Flujo Vehicular.</i>	38
Figura 24. <i>Conjunto de Datos Etiquetados.</i>	43
Figura 25. <i>Gráficas de la Pérdida en Cajas Delimitadoras.</i>	44
Figura 26. <i>Matrices de Confusión de los Entrenamientos Realizados.</i>	45
Figura 27. <i>Gráficas de la Precisión Alcanzada en los Entrenamientos.</i>	46
Figura 28. <i>Gráficas de Recall Obtenido.</i>	47
Figura 29. <i>Gráficas de la Relación entre Precisión y Recall.</i>	48
Figura 30. <i>Gráficas de la Curva F1.</i>	49
Figura 31. <i>Batch generados en los entrenamientos.</i>	50

Figura 32. *Captura de Video Analizado con Yolov5 en la Zona de Interés. 51*

Índice de anexos:

Anexo 1. <i>Base de Datos en Roboflow</i>	66
Anexo 2. <i>Códigos para el Funcionamiento de Yolov5</i>	66
Anexo 3. <i>Detecciones en los vídeos analizados con Yolov5</i>	66
Anexo 4. <i>Repositorio del Proyecto IR_5</i>	66
Anexo 5. <i>Resultados del Flujo Vehicular desde PyCharm</i>	66
Anexo 6. <i>Certificado de traducción del resumen</i>	68

1. Título

Determinación del flujo vehicular en una zona crítica de la ciudad de Loja aplicando YOLOv5.

2. Resumen

Para el desarrollo de este proyecto, se aplicó un método alternativo para calcular el flujo vehicular de una zona estratégica y con alta afluencia de tránsito en la ciudad de Loja - Ecuador, dado que, en dicha zona, existe una necesidad de mejorar el control de tráfico producido. Actualmente pocas son las ciudades que utilizan tecnologías de inteligencia artificial que apliquen modelos de visión por computadora, ya que estas tareas suelen requerir del razonamiento humano. Los algoritmos empleados son capaces de obtener un aprendizaje profundo para la detección y clasificación de objetos, demostrando su eficacia y ofreciendo una innovadora solución para el monitoreo del tráfico.

Durante el proceso, se recopiló una base de datos con 3344 imágenes del entorno puesto a estudio, que posteriormente fueron utilizadas para entrenar un modelo en Yolov5 de manera local en una computadora portátil. El entrenamiento alcanzó un 91.3% de mAP50 (mean Average Precision al 50%), junto con otras métricas altamente positivas. También se implementó un sistema en PyCharm, para detectar y contabilizar vehículos en grabaciones de video utilizando Python como lenguaje de programación, permitiendo así obtener las variables necesarias para calcular el flujo vehicular en términos de vehículos/segundo (veh/s) y vehículos/minuto (veh/min).

Los resultados obtenidos validan la efectividad del uso de modelos de visión computarizada para el análisis del tráfico, mostrando que este enfoque metodológico puede aplicarse para mejorar significativamente la gestión del tránsito en áreas urbanas.

Palabras clave: Congestión de tránsito, flujo vehicular, Python, PyCharm, Yolov5.

Abstract

For the development of this project, an alternative method was applied to calculate the vehicular flow in a strategic area with high traffic in the city of Loja - Ecuador, due to the need to improve traffic control in that zone. Currently, few cities use artificial intelligence technologies that apply computer vision models, since these tasks often require human reasoning. The algorithms used are capable of obtaining deep learning for object detection and classification, demonstrating their effectiveness and offering an innovative solution for traffic monitoring.

During the process, a database of 3,344 images from the study area was compiled, and later used to train a Yolov5 model locally on a laptop. The training achieved 91.3% mAP50 (Mean Average Precision at 50%), along with other highly positive metrics. A system was also implemented in PyCharm to detect and count vehicles in video recordings using Python as the programming language, allowing the necessary variables to be obtained to calculate vehicular flow in terms of vehicles per second (veh/s) and vehicles per minute (veh/min).

The results obtained validate the effectiveness of using computer vision models for traffic analysis, showing that this methodological approach can be applied to significantly improve traffic management in urban areas.

Keywords: traffic congestion, vehicular flow, Python, PyCharm, Yolov5.

3. Introducción

Durante los últimos años, el parque automotor de la ciudad de Loja, se ha visto envuelto en un notable crecimiento, debido a la necesidad humana de transportarse de un lugar a otro. Esto se ve reflejado en el censo de matriculación local que se registra cada año en el (INEC) y la Agencia Nacional de Tránsito del Ecuador. Es aquí donde surgen problemas a la hora de transitar con vehículos por las vías urbanas puesto que la infraestructura vial llega a ser insuficiente por el continuo crecimiento del parque automotor local. Además, se suman otros factores como los congestionamientos vehiculares, accidentes, infracciones, falta de señalética, que merman la seguridad vial, el control de tráfico y el tránsito fluido. Tal y como lo muestra el (INEC), la problemática que conlleva el crecimiento de automóviles se mantiene año tras año, por lo que es necesaria la creación de estrategias que ayuden a regular y gestionar este tipo de sucesos.

Cada vez son más las investigaciones que se suman a las diferentes aplicaciones que brindan los modelos de redes neuronales convolucionales, dado que estas herramientas facilitan la elaboración e interpretación de la información que se puede llegar a recopilar en las vías de tránsito, es vital procesar estos datos para gestionar la movilidad vehicular de la ciudad. El concepto tomado en cuenta para la investigación, es fundamental en el diseño de infraestructura vial, gestión de tráfico, seguridad vial o planificación urbana, (Ogoño Anguisaca & Orozco Calva).

A lo largo de la última década, y a día de hoy, se han desarrollado sistemas que simulan el raciocinio humano, así pues, You Only Look Once (YOLO), en su quinta versión, sigue siendo una de las versiones más completas que se ha desarrollado como red neuronal convolucional; también, Yolov5 se puede desempeñar en diferentes entornos de desarrollo integrado (IDE), por consiguiente, es un método idóneo para la elaboración del proyecto, no obstante se ve limitado por los recursos computarizados disponibles.

Como muestran (Snegireva & Kataev, 2021), la aplicación de tecnologías que involucren inteligencia artificial, como lo es Yolov5, ayudan a la creación de datos estadísticos para el control y regulación del tráfico en las vías. Estos estudios están en constante evolución, debido a que, cuanto más grande sean los conjuntos de datos, mejor serán las métricas y procesos de detección. Por otro lado, (Ashhad, Cabrera, & Roa, 2020) realizan la captación de datos vehiculares, de manera manual, con el fin de dar una solución efectiva al excesivo tráfico que se ocasionaba en una zona específica de la ciudad de Guayaquil; este tipo de estrategias

para mejorar el flujo de circulación de vehículos son efectivas, no obstante, el procesamiento de datos es más lento comparado con la sistematización que se puede llegar a aplicar.

Existen métodos por los cuales se puede analizar el flujo vehicular, pero sin duda, las tecnologías de visión por computadora, mejoran el procesamiento de toda la información recopilada. Este framework, ofrece un sin número de aplicaciones dentro del sector automotriz, por ello, se emplea para calcular la cantidad de vehículos que transitan, en un tiempo determinado, por la Avenida Isidro Ayora y la Avenida 8 de Diciembre, sentido oeste-este con coordenadas -3.977024, -79.204946, (Maps, 2024), sector del terminal terrestre de la ciudad de Loja. Estas avenidas han sido la entrada principal de tránsito vehicular a la urbe lojana por décadas, y a día de hoy sufren las consecuencias del incremento de vehículos que transitan por las vías locales. Además, al ser comparada con una zona de similares características, se observa un notorio contraste en el número de accidentes y sanciones, lo que llega a ser un determinante relevante para aplicar un estudio en la zona de interés ya mencionada.

Para lograr el objetivo, se recopiló una base de datos de 3344 imágenes, del flujo vehicular de la zona conflictiva, que serán puestas a análisis para crear un etiquetado de vehículos que contienen las mismas; además de configurar entrenamientos con Yolov5 para enseñar al modelo a detectar y clasificar automotores, y de este modo, aplicar lo aprendido en un análisis que conlleva determinar el flujo vehicular. Finalmente, con ayuda de PyCharm se desarrolla un sistema, en lenguaje de Python, para contabilizar los vehículos detectados y con ayuda del tiempo transcurrido aplicar la fórmula matemática del flujo vehicular. Esta actividad reduce significativamente el tiempo del procesamiento de datos, volviéndose más eficiente que los métodos tradicionales. Con esta información se puede indagar en el comportamiento que tiene el tránsito de la zona analizada, en horarios y días específicos.

4. Marco teórico

4.1 Flujo vehicular

Para definir este concepto, (Espinel & Jaramillo , 2022) dicen que las principales características de un flujo vehicular son: el volumen vehicular, velocidad y capacidad; dado que estos parámetros ayudan a visualizar los problemas de congestión ocasionados por los vehículos ya que permiten al sistema que opera mejorar notablemente. Es importante saber el alcance y beneficios que tienen este tipo de investigaciones, puesto que, todos los ciudadanos del país circulamos por vías peatonales o vehiculares. La información recopilada por los análisis de flujo vehicular dan conocimiento, a los ingenieros afines, para el diseño y creación de carreteras que abastezcan la circulación y eviten colapsos o congestiones dentro de la población; así mismo, la seguridad es otro factor importante a tomar en cuenta por los ingenieros, ya que permiten: el control de límites de velocidad, dimensionamiento de vías, coordinación de la semaforización, optimización de las rutas de transporte público, reducción de los gases de efecto invernadero e información a la ciudadanía para que tome rutas alternativas (Ashhad, Cabrera, & Roa, 2020).

Finalmente, para cuantificar el flujo vehicular, se utiliza la llamada tasa de flujo vehicular, dado que, a través de ella, no solo se mide la cantidad de vehículos en un punto específico de un periodo, sino que es una medida mayormente específica dada en *vehículos/hora*. Con las siguientes formulas principales, se puede determinar un flujo vehicular en distintas unidades de tiempo utilizando la tasa de flujo vehicular de acuerdo con el libro (Cal & Cárdenas, 2018):

$$\text{Tasa de flujo } \left(\frac{\text{vehículos}}{\text{hora}}\right) = \frac{\text{Número de vehículos}}{\text{Duración del periodo de tiempo (en horas)}} \quad (\text{Ecuación 1})$$

$$\text{Tasa de flujo } \left(\frac{\text{vehículos}}{\text{minuto}}\right) = \frac{\text{Número de vehículos}}{\text{Duración del periodo de tiempo (en minutos)}} \quad (\text{Ecuación 2})$$

$$\text{Tasa de flujo } \left(\frac{\text{vehículos}}{\text{segundo}}\right) = \frac{\text{Número de vehículos}}{\text{Duración del periodo de tiempo (en segundos)}} \quad (\text{Ecuación 3})$$

Con estas fórmulas se puede determinar un flujo vehicular basado en un periodo específico de la zona puesta a estudio. Es importante saber que, para obtener resultados precisos, el número de vehículos y la duración del periodo de tiempo se expresen en la misma unidad que aparecen en las fórmulas.

4.2 Elementos del flujo de Tránsito

La teoría de flujo de tránsito nos habla acerca de las relaciones que poseen sus elementos: flujo, densidad y velocidad; se aplican en diseños de carreteras que determinan el tamaño, ubicación de los carriles, los posibles giros, tiempo de espera en las intersecciones y rampas de acceso a viaductos, además de obtener información real de los cambios de flujo vehicular, tiempo de viaje, contaminación del aire y el consumo de combustible en una zona de tránsito, (Blanco, Dorantes, Gómez, & Morales, 2017).

4.2.1 El flujo (q)

Para los autores (Blanco, Dorantes, Gómez, & Morales, 2017) indican la cantidad de vehículos que transitan por una zona en específica en un determinado periodo de tiempo, este generalmente es inferior a 1 hora, lo podemos calcular mediante esta fórmula:

$$q = \frac{n \times 3600}{T} \text{ veh/h} \quad (\text{Ecuación 4})$$

Donde:

n = número de vehículos que transitan por un punto en el camino en T segundos

q = el flujo horario equivalente

4.2.2 La densidad (k)

Según (Blanco, Dorantes, Gómez, & Morales, 2017) señalan la cantidad de vehículos que se encuentran en un segmento específico de una vía, expresado la densidad en vehículos por kilómetro; este valor puede variar dependiendo el segmento que se consideró y el tiempo empleado en la medición.

4.2.3 La velocidad (u):

De acuerdo con (Blanco, Dorantes, Gómez, & Morales, 2017) muestra la distancia que un vehículo puede recorrer en un periodo de tiempo determinado; esta se la puede cuantificar en diferentes unidades como: millas por hora (mi/h), kilómetros por hora (km/h), o en pies por segundo (ft/seg).

4.2.4 Velocidad media en el tiempo (\bar{u}_t)

Un elemento adicional que nos brinda el flujo de tránsito, es la \bar{u}_t . (Blanco, Dorantes, Gómez, & Morales, 2017) señalan que se calcula cuantificando el segmento de vía analizado, entre el tiempo promedio que los vehículos tardan en recorrer dicho segmento; dentro de este análisis se toman en cuenta las congestiones vehiculares o demoras que se puedan producir. Para calcularla se emplea la siguiente formula:

4.3 Variables relacionadas con el flujo

Anteriormente se mencionó algunas de las variables que se conectan directamente con el flujo vehicular, pero existen dos variables adicionales que se deben tomar en cuenta para el análisis del mismo, (Mozo, 2012):

4.3.1 Intervalo simple entre vehículos consecutivos (h_i);

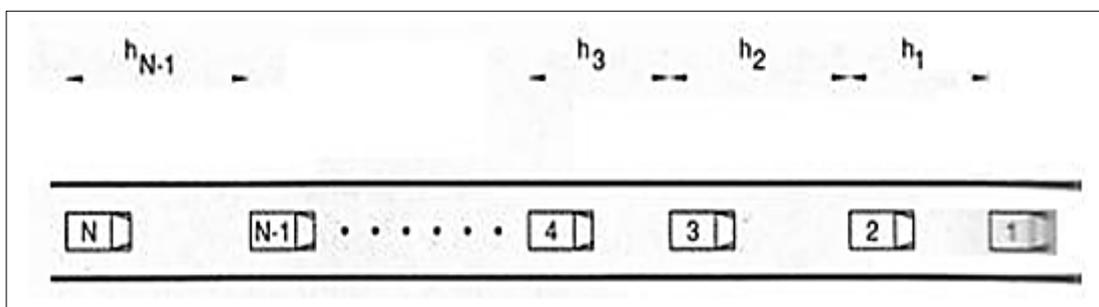
Es el espacio de tiempo que existe entre dos vehículos consecutivos al pasar por un punto específico, este se mide entre dos puntos homólogos por cada par de vehículos que generalmente son expresados en segundos (Mozo, 2012).

4.3.2 Intervalo promedio entre vehículos (\bar{h});

Se refiere al promedio de todos los intervalos simples, (h_i), circulantes en la vía analizada, (Mozo, 2012). Dado que es un cálculo de promedio, se expresa en segundos por vehículo (s/veh) mediante la siguiente ecuación:

Figura 1

Intervalos entre Vehículos.



Nota. Adaptado de “Ingeniería de Tránsito, Fundamentos y aplicaciones” [Gráfico], por J. Reyes, y otros, 2007 (<https://hdl.handle.net/20.500.14330/TES01000670331>) Licencia estándar.

Como dato adicional, se observa que el intervalo promedio, h , posee las unidades inversas a las del flujo vehicular (q), por lo tanto, también se debe considerar la siguiente ecuación:

$$\bar{h} = \frac{1}{q} \quad (\text{Ecuación 5})$$

4.4 Congestionamiento vehicular

Este fenómeno muestra la capacidad de demanda que tiene una red vial para ser superada; dando como resultado un desplazamiento más lento de los vehículos y un notorio aumento en el tiempo de viaje. La congestión vehicular puede ser causada por el aumento progresivo del parque automotor, ya que el diseño de las vías e infraestructura han ido disminuyendo su eficiencia con el pasar de los años; por otro lado, las condiciones climáticas adversas, accidentes de tránsito o el incremento de la población urbana, también contribuyen para que el flujo sea más lento. Es posible que este suceso genere costos significativos en la productividad laboral, costos operativos y pérdidas económicas en general, además de incrementar el estrés, contaminación del aire y ruido ambiental.

Por lo cual es de suma importancia social la planificación urbana que pueda llegar a tener una ciudad; por ello, las tecnologías de gestión de tráfico optimizan de mejor manera la captación de datos para establecer la gestión de estos problemas, que a futuro serán solucionados con políticas de control vehicular y estrategias de control de congestión. (Carpio Quizhpi & Mejía Carpio, 2023)

4.5 Redes neuronales convolucionales

En primer lugar, una red neuronal es un modelo computacional semejante al funcionamiento del cerebro humano, pero desde una perspectiva matemática ya que, el funcionamiento exacto del cerebro no se podría emular biológicamente, (Alarcon, 2022). Se usa para explorar y perfeccionar los patrones de adiestramiento vigilado y no vigilado, por ejemplo, sirven para identificar los vehículos circundantes por una vía en un periodo de tiempo. De este modo, se podrá obtener información acerca del tráfico, (Flores, 2020). Se reconocen tres características principales en una red neuronal:

- La arquitectura de la red neuronal
- El entrenamiento
- La función de activación.

Esta última característica se la denomina como una función matemática que establece la salida de una neurona, además, recibe una coordinación de los pesos con los valores que se presentaron en la entrada. Así se establece si la siguiente neurona se debe activar o no, además de normalizarla al final del proceso. Hay funciones de activación que se pueden emplear durante el desarrollo: función sigmooidal o logística, función tangente hiperbólica (Tanh), función de activación lineal rectificadora (ReLU), unidad de linealidad rectificadora paramétrica (PReLU), SoftMax y ReLU Leaky (ReLU con fugas). Por otro lado, un tipo de red neuronal especializado, son las redes neuronales convolucionales que son frecuentemente usadas para procesar imágenes, puesto que son capaces de encontrar detalles o elementos de gran importancia, pero se debe reducir el número de parámetros para evitar que el número de neuronas conectadas sea excesivamente alto y en su defecto reducir parámetros y ser más profundos en la red, (Flores, 2020).

Las redes convolucionales acogen entradas como un vector, cuando la entrada es de una dimensión (por ejemplo, un micrófono), una matriz, cuando la entrada tiene dos dimensiones (imágenes en blanco y negro) o tal vez un tensor, si la entrada posee más de dos dimensiones (imágenes a color). En la salida puede darse la situación de usar una clasificación Softmax o una convencional, (Berzal, 2018)

4.6 YOLOv5

Catalogado como un popular framework y modelo de detección de objetos en tiempo real o imágenes de entrada. YOLO es caracterizado por su alta velocidad y precisión a la hora de detectar objetos en imágenes o secuencias de imágenes (videos). La quinta versión de YOLO se denomina YOLOv5, dado que es una reiteración de un modelo más reciente al original. Esta versión mejoró la eficiencia y la precisión de la comparación de imágenes, además de otras características como: una arquitectura más ligera, soporte para múltiples tamaños de objetos y la facilidad de uso. Esta arquitectura se la presentó en un artículo llamado “*You Only Look Once: Unified, Real-Time Object Detection*” procedente de (Redmon, Divvala, Girshick, & Farhadi, 2015) basándose en la arquitectura de GoogLeNet (Szegedy, y otros, 2014), con esta composición cada celda genera diferentes tamaños de *bounding boxes*, estableciendo niveles de confianza para la predicción de un objeto real, (Valls, 2023).

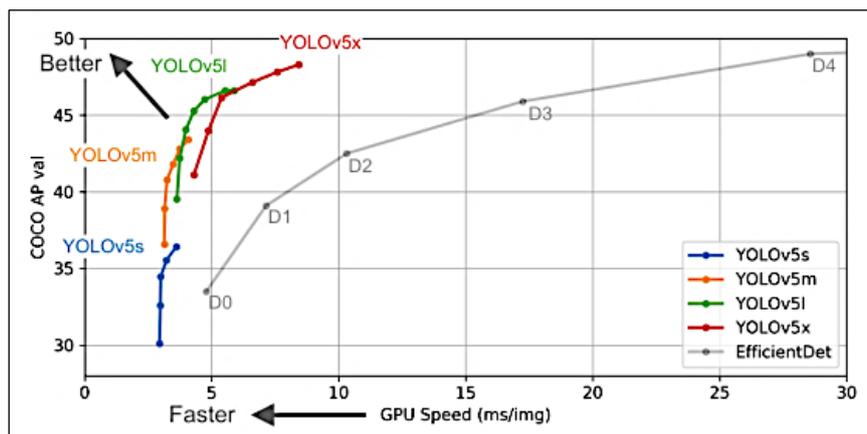
YOLOv4 y YOLOv5 agregaron cambios que ocasionaron mejoras en los *benchmark*, de este modo, redujeron el tiempo de entrenamiento; además la arquitectura se desarrolló nativamente en PyTorch y no en *Densenet* como se hacía en las versiones anteriores a la quinta.

Existen diferentes subversiones dentro de la misma versión, para ser más específicos, YOLOv5 posee cinco versiones diferentes que manejan parámetros de distinto tamaño, estos son: YOLOv5n (nano), YOLOv5s (small), YOLOv5m (medium), YOLOv5l (large) y YOLOv5x (extra large). Estos modelos se los denomina P5 cuyo diseño está hecho para entrenar en imágenes con resoluciones de hasta de 1280 x 1280, a diferencia de los modelos P6 cuya resolución es de 640 x 640. El aumento del tamaño de resolución, estimula a mejorar la precisión de la red, además de inferir en menor velocidad; por lo que las mejoras se basan en la rapidez y precisión con la que detectan objetos en las imágenes, (Valls, 2023).

YOLOv5 es uno de los algoritmos más rápidos para la detección de objetos que trabaja con redes convolucionales. Para entrenar la red neuronal, se necesita tener anotaciones en el formato propio de boxes y crear tres archivos, donde inicialmente habrá datos con los que YOLO entrenará, en segundo lugar, existirán los datos o archivos denominados hiperparámetros, quienes serán los mejores y más fáciles de detectar, y, por último, un archivo que configure el número de clases con las que trabajará la red y la arquitectura del modelo, (Martínez, 2022).

Figura 2

Benchmark de YOLOv5



Nota. Adaptado de “Evaluación de rendimiento de YOLOv5 y algoritmos de seguimiento en una Jetson nano 2GB” [Gráfico], por Vall, 2023 (<https://repositorio.uchile.cl/handle/2250/191847>). Licencia estándar.

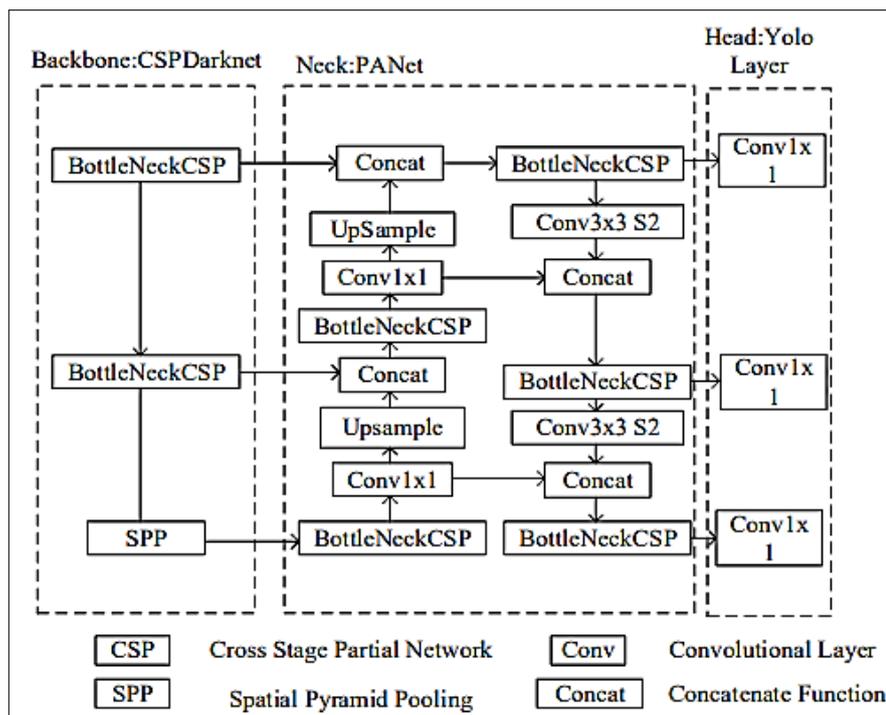
Para desarrollar un proyecto con herramientas de etiquetado se puede utilizar Make Sense o Roboflow, donde a través de un recuadro se marca el objetivo a detectar. Una vez localizado el objetivo en la imagen, se clasifican en diferentes clases. Terminado este proceso

de etiquetado y clasificación se obtienen los archivos .txt, que contienen las coordenadas de los bounding boxes que se establecieron en cada una de las fotografías. Hay estudios donde se utilizaron 5000 imágenes puestas a entreno, y con aproximadamente 12000 vehículos captados como objetivo, (Shao, Wu, Li, & Li, 2023).

El algoritmo de coordenadas es utilizado para comparar los objetivos de las imágenes de entrenamiento con las imágenes captadas en tiempo real. La versión YOLOv5s optimiza unas multientradas para captar más de un objeto simultáneamente, no obstante, las entradas se unifican y estandarizan antes de cualquier entrenamiento, (Shao, Wu, Li, & Li, 2023). YOLO incluye módulos como el CBL, Focus, SPP y el CSP; estos, realizan funciones de estandarización y activación de los objetivos, para luego ser transferidos al módulo Focus, esto reduce la pérdida de datos de la imagen para posteriormente bajar la resolución de las mismas, y, que el módulo SPP, extraiga características de la imagen y las envíe al módulo CSP para integrar el proceso, (Shao, Wu, Li, & Li, 2023). El modelo YOLOv5 se muestra en la siguiente imagen:

Figura 3

Diagrama del Modelo de Red YOLOv5.



Nota. Adaptado de “A vehicle recognition model base don improved YOLOv4” [Imagen], por Shao y otros, 2023 (<https://doi.org/10.3390/electronics12061323>). Licencia estándar.

4.7 Capas convolucionales de YOLOv5

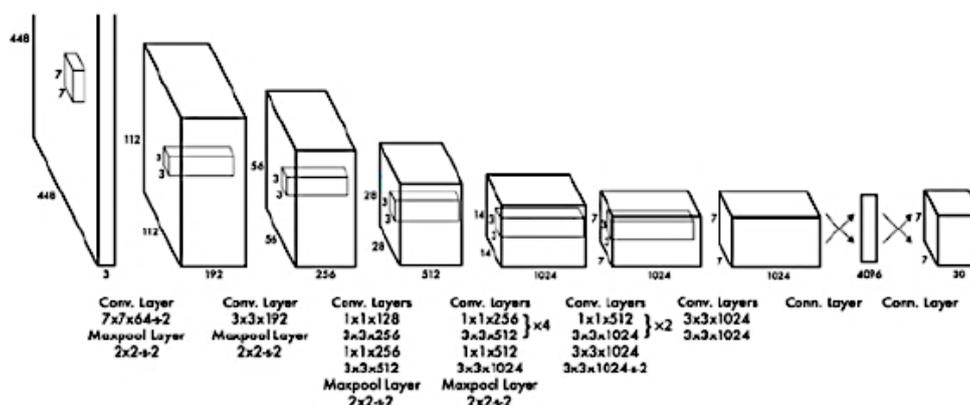
Este elemento, localiza y aprende patrones introducidos y jerarquías espaciales, además de proveer de cognición de las características más usuales de un problema. Es distinto en una red neuronal multicapa que interviene en el subconjunto de las entradas para detectar una característica, si detecta algo de utilidad, realizará una búsqueda similar en la siguiente entrada procesada. (Berzal, 2018). El autor del libro “*Redes neuronales & Deep Learning*” declara que las redes neuronales convolucionales están compuestas por una arquitectura de secuencia de capas, que altera la entrada y genera una salida para presentar tres tipos de capas: convolucionales, pooling y capas enteramente conectadas. Hay distintos tipos de combinaciones, por ejemplo, lo más común es la mezcla de capas convolucionales y capas de pooling; sin embargo, también pueden combinarse con alguna capa de modelo ReLU. Pero la red se finaliza de manera más común con una capa de estilo softmax, (Berzal, 2018).

Esta red neuronal puede ser implementada en PyTorch, por lo que mejora en aspectos de velocidad de procesamiento y en compatibilidad con más librerías de los diversos sistemas operativos existentes. Para realizar todo el proceso de entrenamiento y detecciones, YOLOv5, pone en funcionamiento una serie de mecanismos por capas que se encargan de aplicar filtros (kernel) en las imágenes de entrada, con el fin de extraer características como bordes, texturas y patrones que se repiten constantemente. Estas detecciones, en primera instancia, lo realizan las capas convolucionales estándar, quienes a medida que se implementan estas capas, el sistema aprende a diferenciar objetos presentes en las imágenes de manera significativa; para que después entren a escena las capas convolucionales con agrupación o *pooling* que disminuyen los parámetros y operaciones en las capas siguientes. De este modo, las capas de detección generan las predicciones de objetos en los cuadros y asigna la clase correspondiente utilizando la información arrojada por las capas previas (Berzal, 2018).

Con las capas de normalización se busca acelerar el proceso de entrenamiento, creando mini lotes de red con los datos, durante los entrenamientos. Las capas de activación se aplican para deslincar la conexión con la red de datos de entrada y salida, esto beneficia en la retroalimentación de información entre las diferentes capas. Por último, las capas de concatenación proveen al sistema de la capacidad de combinar información de los múltiples niveles de capas. Específicamente YOLOv5 se constituye de 28 capas convolucionales en los diferentes niveles y dos capas adicionales conectadas directamente (Berzal, 2018).

Figura 4

Esquema de la Arquitectura de la Red Neuronal



Nota. Adaptado de “Analysis of Pruned Neural Networks (MobileNetV2-YOLO v2) for Underwater Objetc Detection” [Imagen], por (Ayob, Khairuddin, Mastafah, Salisa, & Kadir, 2021)(https://doi.org/10.1007/978-981-15-5281-6_787). Licencia estándar.

4.8 Métricas de YOLOv5

Cuando los procesos de entrenamiento con YOLOv5 finalizan, se obtiene un conjunto de datos importantes que describen las características alcanzadas por el modelo. (Caicedo M., 2023). Esta información básicamente consta de gráficas, histogramas, diagramas de dispersión y un resumen detallado de las métricas en cada época de entrenamiento; para ello se definen los siguientes conceptos:

- **Verdaderos Positivos (VP):** el modelo detecta de manera acertada un objeto.
- **Falso Positivo (FP):** se detectan objetos que no existen realmente en la imagen.
- **Falso Negativo (FN):** objeto no detectado estando en la imagen.
- **Verdadero Negativo (VN):** objetos que correctamente no se detectaron.

(Caicedo M., 2023) establece estas definiciones de las métricas que el sistema YOLOv5 es capaz de calcular:

Precisión: es la relación existente entre los verdaderos positivos (VP) y el total de predicciones positivas.

Recall: definida como la relación existente de los verdaderos positivos y la suma de los verdaderos positivos y falsos negativos:

F1-score (F1): medida que relaciona la precisión y el recall de manera equilibrada ajustándose a los mejores umbrales de confianza durante las detecciones:

mAP (Mean Average Precision): es el promedio de precisión de todas las clases obtenido en el rango de 0 a 1:

4.9 Investigaciones relacionadas

La última década ha sido testigo de un importante número de investigaciones en lo que a redes convolucionales y YOLOv5 respecta. Entre los más recientes se encuentra, (Chen, Cao, & Wang, 2022), quienes tratan de resolver, mediante un algoritmo adaptado a YOLOv5, la pérdida de características que un UAV (Unmanned Aerial Vehicle) sufre a la hora de captar imágenes de alta resolución ; para ello, (Chen, Cao, & Wang, 2022), modifican el algoritmo original, lo entrenan con imágenes de alta resolución procedentes de otros UAV, donde se etiquetan los vehículos y sus coordenadas, para finalmente obtener fragmentos del algoritmo de recorte adaptativo que se fusionará con las coordenadas y el mapeo de posición. Sus resultados fueron muy positivos, ya que aumentaron en un 91,9% la precisión del algoritmo original (79,5%); esta adaptación del algoritmo mejoró eficientemente el rendimiento de detección de objetos tradicional, (Chen, Cao, & Wang, 2022)

Por otro lado, (Li, Yang, Lin, Zhang, & Wu, 2023), introducen una red piramidal bidireccional (BiFPN) en el modelo basado de YOLOv5, para mejorar las características del algoritmo a varias escalas; además, Soft-NMS (Supresión suave No Máxima) agrega un filtro de cuadros de predicción para disminuir la pérdida de detección de vehículos debido a la estrecha alineación entre los mismos. Sus resultados demostraron que aumentó en un 3,7% y un 4,7% los índices de precisión y recuperación de imágenes capturadas por un UAV, (Li, Yang, Lin, Zhang, & Wu, 2023).

En otro enfoque de estudios relacionados con las redes neuronales convolucionales, se mencionan a (Montenegro & Flores, 2022), ellos, nos acercan un poco más a la detección de peatones usando YOLOv5. Para cumplir con este propósito, diseñaron dos subredes que trabajan en la detección de imágenes a color (RGB) y térmicas (IR). A través de otra subred, fusionan las redes RGB e IR con la red principal de YOLO, logrando así un detector de peatones tanto en el día como en la noche. Sus conclusiones establecieron que las subredes mejoraron en un 96.6% con respecto a la base de datos INRIA; sobre los datos CVC09 un 89,2%, en LSIFIR un 90,5%, un 56% sobre FLIR-ADAS, 79,8% para CVC14, 72,3% en Nightowls y en KAIST un 53,3%. (Montenegro & Flores, 2022).

También existen estudios de (Snegireva & Kataev, 2021) quienes aplican una red neuronal para la clasificación de vehículos en un tránsito vehicular. Para ello, entrenaron un sistema de detección de objetos avanzado con YOLOv5, y obtuvieron 750 imágenes de las cámaras de vigilancia existentes en la ciudad; esta recopilación de datos se empleará en futuros estudios estadísticos que regulen de manera eficaz el tránsito en las vías. Los resultados expresaron que, las pruebas realizadas en el sistema de detección de vehículos tuvieron una precisión del 89%, (Snegireva & Kataev, 2021), este porcentaje se asemeja al establecido por el algoritmo original de YOLOv5.

Se desarrolló un estudio de vialidad donde (Ruiz, Sánchez, & Arteaga, 2019) presentan una solución a las aglomeraciones de tráfico en el casco céntrico de la ciudad de Loja, Ecuador. Para alcanzar sus objetivos, organizan y distribuyen el tránsito de acuerdo a las necesidades y disponibilidad de las vías públicas, a través de dos modelos que organizan el tráfico enfocado en dos situaciones frecuentes de la ciudad. El primer escenario que se puede modificar, es a través de la calibración de semáforos, modelizando a estos, con el modelo más reciente de la ciudad; el segundo, da paso a un Regeneración Urbana quien fomenta la peatonalización de algunas calles que frecuenten colapsos vehiculares. Los resultados resuelven los problemas de tráfico de la ciudad de Loja, (Ruiz, Sánchez, & Arteaga, 2019).

Si dinamizamos la aplicación de tecnologías diferentes a las tradicionales, aparece PTV Vissim un software de simulación macroscópica y multimodal de tránsito que (Díaz Silva & Horna Martínez, 2022) utilizaron en su proyecto para recrear el tráfico de una intersección en la ciudad de Jaén, de este modo pueden modificar el sentido de circulación, agregar prohibiciones o señalética, tanto para vehículos como para peatones; con esto, consiguieron una mayor fluidez en el tránsito de automotores y un correcto ordenamiento peatonal que eviten accidentes, (Díaz Silva & Horna Martínez, 2022).

Existen investigaciones aledañas que determinan el nivel de servicio de una intersección de avenidas en la ciudad de Portoviejo-Manabí-Ecuador, mediante la recopilación de aforo que suelen tener estas vías, determinan el flujo de saturación y las demoras que presentan los vehículos por segundo, además toman en cuenta los procedimientos que propone el HCM (Manual de Capacidad de Carreteras), con el fin de indagar si la intersección requiere de ser removida de sus características u en su defecto, agilizar el flujo vehicular que se produce, (Gómez & Delgado , 2022).

En el mismo entorno que envuelve al sistema HCM, (Carpio , Avilés, & Morillo, 2018) aplicaron este método para sobreestimar la capacidad de seis vías de doble carril mediante el estudio transversal en secciones durante el periodo agosto 2015 a febrero 2016; se obtuvieron

resultados alarmantes, donde el 56% de promedio indica que las carreteras están sobre pobladas en comparación al método HCM de Estados Unidos, por ello, este sistema no puede ser aplicado en carreteras cuencanas, (Carpio , Avilés, & Morillo, 2018). En último lugar (González Cartagena, 2023) recopiló información en fichas de observación para jerarquizar las rutas de circulación vehicular que en el centro de la ciudad de Nueva Loja necesita para evitar el congestionamiento. Para cumplir el objetivo (González Cartagena, 2023), consideraron la cantidad y tipo de automotores, longitud de la cola de tráfico, reparto del tiempo y los ciclos de semáforo existentes en la zona.

A día de hoy existen los recursos suficientes para investigar las zonas urbanas que tienen algún tipo de conflicto de tránsito, la necesidad de esto es vital para mejorar la calidad de vida de los lojanos, evitar la contaminación y activar la economía local. La industria automotriz debe ser pionera en la planificación de tránsito y seguridad vial en las zonas de flujo vehicular, por ello, mejorar y optimizar los métodos comunes para la toma de datos y procesamiento de los mismos, ayudará a la automatización de estos procesos que de manera manual conllevan más tiempo.

5. Metodología

5.1 Selección de la zona de estudio.

A lo largo del día se producen fenómenos de saturación vehicular en diferentes zonas de la ciudad de Loja, lo que provoca una serie de molestias en los conductores que transitan en horas clave del día. Los horarios que suelen tener mayor afluencia empiezan en la mañana; continúan al medio día, donde se puede observar un significativo incremento en el tránsito, y finaliza al caer la noche con la misma problemática. Por lo que, actualmente la provincia de Loja tiene una población de 485421 habitantes, de los cuales 250028 habitantes pertenecen a la ciudad y capital provincial; según (INEC, 2023) cada año esta cifra se ve incrementada por el desarrollo urbano que esta ofrece.

Uno de los principales accesos y salidas que tiene la urbe lojana es la Avenida Isidro Ayora, esta arteria, también conocida como Panamericana E35, empieza en el límite territorial por el Oeste de la ciudad y finaliza conectando, en el Este, con la Av. Darío Eguiguren. Durante el recorrido por la Av. Isidro Ayora se encuentra una intersección no semaforizada con la Avenida 8 de Diciembre, punto bastante conflictivo, ya que en este encuentro, se localiza el terminal terrestre Reina del Cisne, por lo que múltiples autobuses de transporte interprovincial frecuentan esta zona. No obstante, al ser una entrada principal de vehículos que llegan desde la sierra y costa, también se suman vehículos de cargas pesadas que van de paso hacia el oriente ecuatoriano (zona este). Según la UCOT (Unidad de Control Operativa de Tránsito), en la zona de estudio, durante los años 2021, 2022 y 2023 se multaron a 369 vehículos por estacionarse en sitios prohibidos, 356 vehículos donde sus ocupantes no portaban el cinturón de seguridad y 140 personas que conducían en estado de embriaguez; además de otras cuantiosas contravenciones. La intersección está dotada de un redondel que ayuda a disolver el tráfico generado, lo que añade al tránsito de la zona, un grupo de vehículos provenientes del norte de la ciudad; por lo tanto, debido al número de accidentes y contravenciones de la zona, se lo considera un punto caliente para poner a estudio el flujo vehicular generado en el lugar; puesto que al ser comparado con zonas de la ciudad con características similares como la intersección de la Avenida Pablo Palacio y Av. 8 de Diciembre se puede observar el contraste conflictivo existente con la zona de interés ya que, según datos estadísticos de la UCOT, durante los mismos años, no se multaron ni a la mitad de los infractores de la zona de estudio. También, (Ruiz, Sánchez, & Arteaga, 2019) aplicaron encuestas (O-D) según la normativa NAVI, en puntos estratégicos de la ciudad, entre ellos, la Avenida 8 de Diciembre, concluyendo que dicha avenida es de las más transitadas de la ciudad. Por otro lado, (Febres Loaiza, 2022) analiza

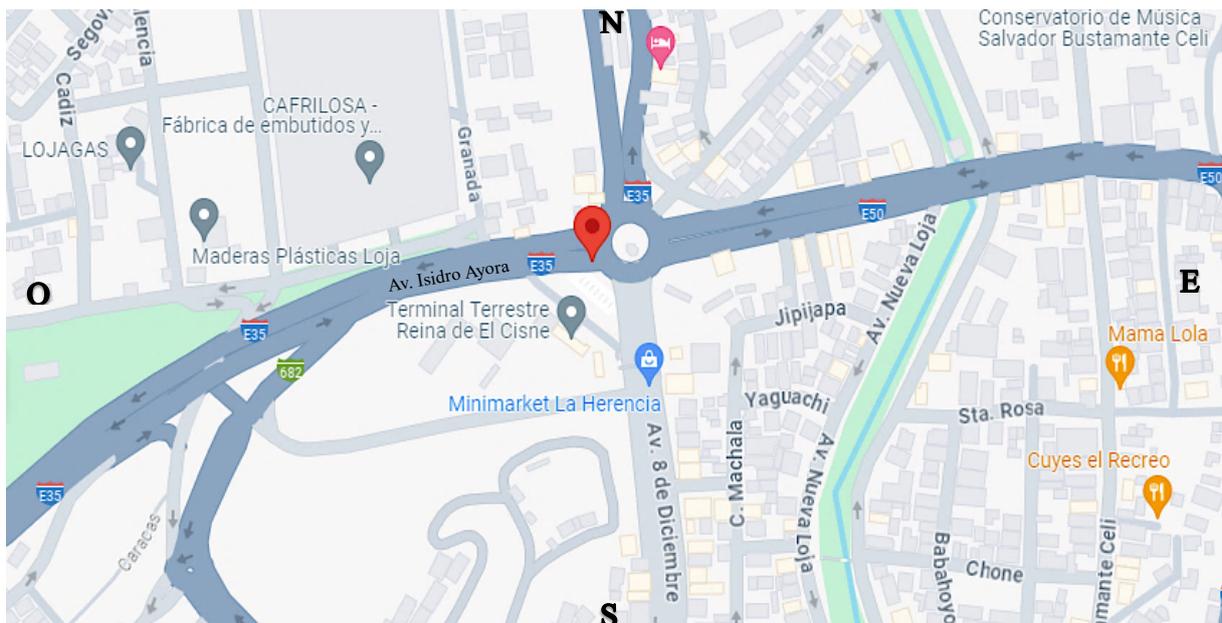
zonas de gran concurrencia de vehículos en el casco céntrico de la ciudad de Loja, con el fin de implementar un sistema de conteo vehicular que ayude a las futuras planificaciones urbanas.

La diversidad de vehículos en el área, hace que la desembocadura al ingreso del redondel por la Av. Isidro Ayora se vea colapsada, (Maps, 2024), lo que, años atrás, ha llevado al Municipio de Loja a implementar un ancho de vía de aproximadamente 9 metros en el mencionado punto, sin embargo, se observa un desorden causado por la falta de señalética en las limitaciones de los carriles que, tomando en cuenta las dimensiones y el tipo de vehículos, este tramo de vía debe regirse a la ordenanza municipal N° 0058-2023, (Municipio de Loja, 2023). Este reglamento dice que las dimensiones de ancho para este tipo de vía urbana deben ser de al menos 3 metros por carril, por lo tanto, al no haber una limitación visual de los carriles existentes, se crean en ocasiones de dos hasta cuatro columnas de vehículos que intentan ingresar al redondel.

Además, las normativas (INEN, 2011), promueven que el dimensionamiento de los carriles por los cuales transitan vehículos pesados, sean superiores a los 3 metros por carril, sin establecer un límite exacto.

Figura 5

Ubicación de la Zona Analizada.



Nota. Imagen obtenida de (Maps, 2024). Muestra el punto exacto donde se realizó el análisis.

5.2 Obtención del conjunto de datos.

5.2.1 Captación de imágenes.

Una vez ubicada y visualizada la zona de análisis, con ayuda de una cámara fotográfica se capturan imágenes del tráfico en las horas de mayor y poca afluencia vehicular; además de imágenes, se grabaron algunos videos de entre 5 a 10 minutos de duración.

La cámara utilizada para la obtención de estas imágenes corresponde al modelo Sony IMX766 de un smartphone SM-A546B. Quien capta imágenes a gran resolución, sin embargo, para el desarrollo del proyecto, el tamaño de imagen se ha relegado a un plano secundario, debido a que YOLOv5 trabaja con un tamaño de imagen de al menos 640x640, para así obtener resultados más óptimos, aunque el algoritmo puede trabajar de forma correcta con tamaños más grandes, esto conlleva la necesidad de usar recursos de hardware más potentes.

Por otro lado, se grabaron videos y se capturaron imágenes adicionales con la cámara de un dron DJI Phantom 4 Pro V2.0, tomando un ángulo elevado al tráfico para simular una cámara de seguridad o cámara de tránsito. Estos videos serán importantes para establecer un conteo exacto de la variedad de vehículos que circulan por los diferentes carriles que posee la vía.

Figura 6

Fotografía del Tránsito Captada con Dron



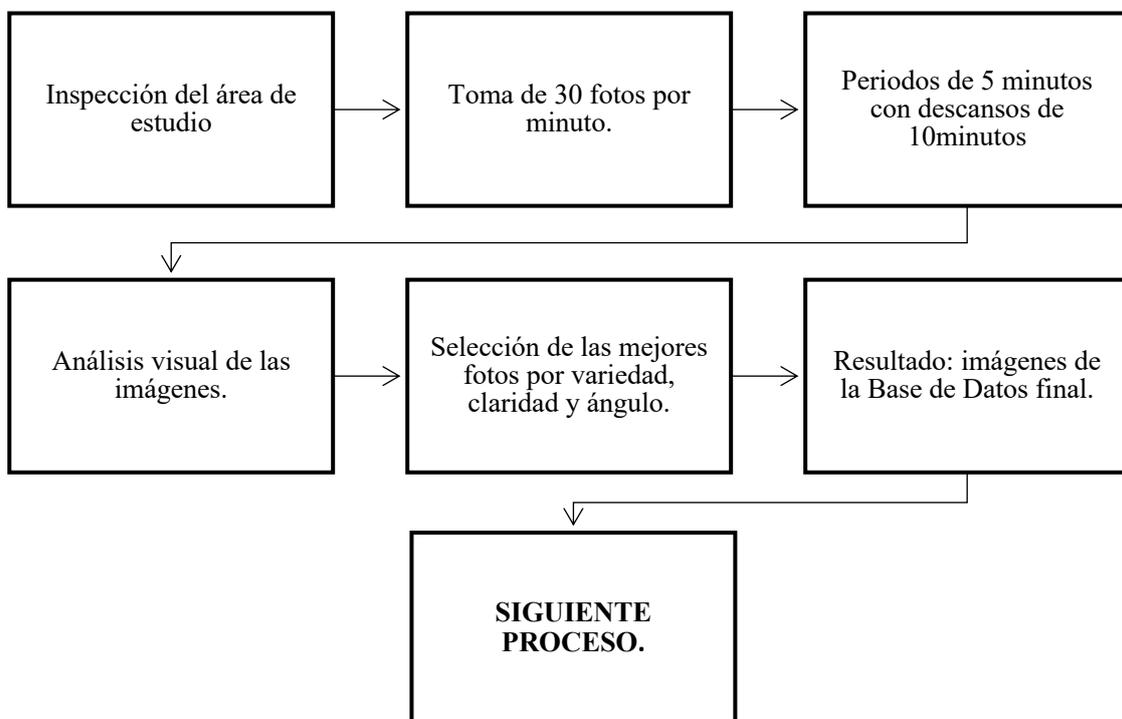
La toma de muestras se la hizo en un patrón de aproximadamente 30 fotografías por minuto, durante periodos de 5 minutos, dejando un descanso de diez minutos entre periodos, tomando en cuenta diferentes ángulos. Las horas pico son cruciales para captar un número mayor de vehículos por imagen, dado que YOLOv5 se adapta a los numerosos ambientes de flujo vehicular. Se busca apreciar el tráfico en horas de la mañana, desde las 7h00 hasta las

8h30; en horas de la tarde, desde las 12h00 hasta las 14h00; y, en horas de la noche, desde las 18h00 hasta las 19h30.

Este proceso se lo realizó los días lunes, miércoles y viernes de las semanas impares del mes existente entre el 15 de enero y 15 de febrero del presente año. También se obtuvieron imágenes de días esporádicos, como feriados o los días domingos de las semanas pares; esto con el fin de tener una base de datos que se adapte a las diferentes situaciones que experimenta el tráfico en la zona, y la variedad de automóviles que pueden llegar a circular por la zona de estudio. Una vez recopiladas todas las fotografías obtenidas, se analizan visualmente para seleccionar las de mejor calidad. Finalmente se descartó alrededor del 39% de 3000 imágenes preseleccionadas de un total de 30000 imágenes obtenidas a lo largo de un mes. Quedando así 1823 imágenes en la base de datos final.

Figura 7

Diagrama de Flujo para Obtención del Conjunto de Datos.



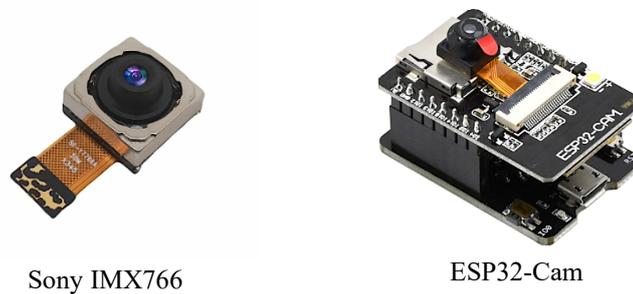
5.2.2 Instrumentos para la captación de imágenes.

Mediante la secuencia de imágenes captadas en la zona de interés, se obtuvieron una serie de fotogramas del tránsito producido en las horas pico de los días lunes, miércoles y viernes. Los diferentes ángulos y distancias ayudaron a obtener una base de datos variada, por

ello, era necesario una cámara que pudiera brindar estas funciones. Sin embargo, en primera instancia se intentó utilizar un módulo ESP32-Cam, con el fin de programarlo para obtener imágenes remotamente, sin embargo, la infraestructura para su instalación requería de servicio de energía eléctrica, además de servicio de internet y protección contra lluvias. Es por ello que se optó por otra alternativa más versátil. La cámara Sony IMX766 brinda una calidad de imagen óptima para captar fotografías en diferentes horas del día, y claramente supera al módulo ESP32-Cam. Dado que solo se usó para la obtención de la base de datos, fue la mejor opción ya que no existían los problemas que se presentaban con el módulo ESP32.

Figura 8

Comparativa de Cámaras para la Captación de Datos.



Nota. Imágenes obtenidas de (Sincerefirst, 2024) y (Ubuy, 2024) respectivamente.

Tabla 1

Características de cámara Sony IMX766 vs ESP32-Cam

Características	Sony IMX766	ESP32-Cam
Tipo de sensor	CMOS	OV2640
Resolución	50 MP	2 MP
Tamaño del sensor	1/1.56 pulgadas	¼ pulgadas
Tamaño de píxel	1.0 µm	2.0 µm
Rango dinámico	Alto	Estándar
Capacidad de conexión	Depende del módulo utilizado	Wifi, Bluetooth (integrado)
Almacenamiento	Externo	Tarjeta MicroSD

Consumo de energía	Moderado, alto	Bajo
Aplicaciones comunes	Smartphones, cámaras de seguridad	Proyectos DIY, IoT
Costo aproximado	Alto	Bajo

Por otro lado, se grabaron videos y captaron fotografías desde un dron DJI Phantom 4 Pro V2.0, con el fin de acceder a un ángulo elevado de aproximadamente 12 a 15 metros, ya que la infraestructura de la zona no brinda acceso a esta altura.

Figura 9

Dron DJI Phantom 4 Pro V2.0



Nota. Imagen obtenida de (Amazon, 2024).

Tabla 2

Características de Dron DJI Phantom 4 Pro V2.0

Características	Detalles
Cámara	Sensor CMOS de 1in, 20 MP a 60fps
Tiempo de vuelo	Hasta 30 minutos
Alcance de transmisión	Hasta 7km
Velocidad máxima de vuelo	72 km/h en modo sport
Controladores	Compatible con controladores con y sin pantalla incorporada

Sensores	Sensor de visión dual adelante, atrás y abajo. Detección de obstáculos en cinco direcciones.
Transmisión	OcuSync 2.0
Batería	5870 mAh, LiPo 4S
Compatibilidad	Con accesorios DJI

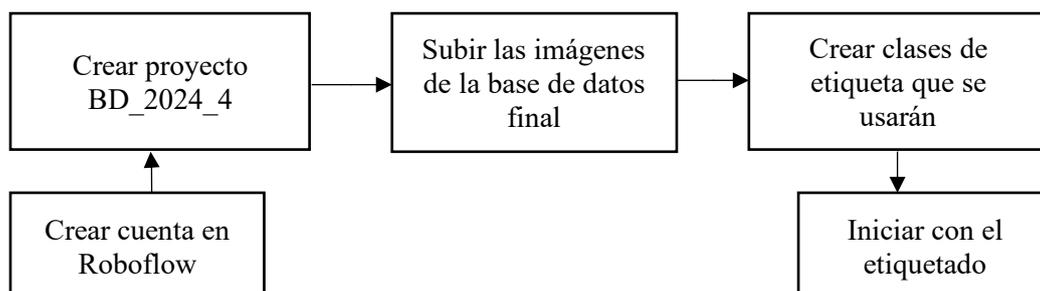
5.2.3 Etiquetado de la base de datos.

Posteriormente, toda la base de datos será sometida a un proceso de etiquetado y clasificación de los vehículos que estas imágenes contienen. Hay múltiples plataformas que brindan el servicio de etiquetado en línea, en el presente proyecto se utilizaron dos plataformas, Make Sense AI y Roboflow, siendo utilizadas para diferentes pruebas de etiquetado y clasificación de vehículos; resultando como mejor opción la plataforma Roboflow, puesto que brinda un sin número de funcionalidades con respecto a modelos de visión por computadora y, sobre todo, los avances se pueden guardar progresivamente a manera de proyecto.

Esta plataforma brinda la capacidad de seleccionar objetos en imágenes y clasificarlos según el tipo de nombre que se designe; esto lo realiza mediante recuadros en las diferentes coordenadas que la imagen posee en sus píxeles. Estas coordenadas establecen la ubicación exacta de un vehículo dentro de la fotografía. El proceso de etiquetado es crucial para mostrarle al sistema ejemplos de los objetos que se desea inferir a futuro. El etiquetado se debe realizar en todos los vehículos que aparecen en la imagen, con diferentes ángulos del automotor, para que a futuro se puedan detectar sin problema en diferentes escenarios.

Figura 10

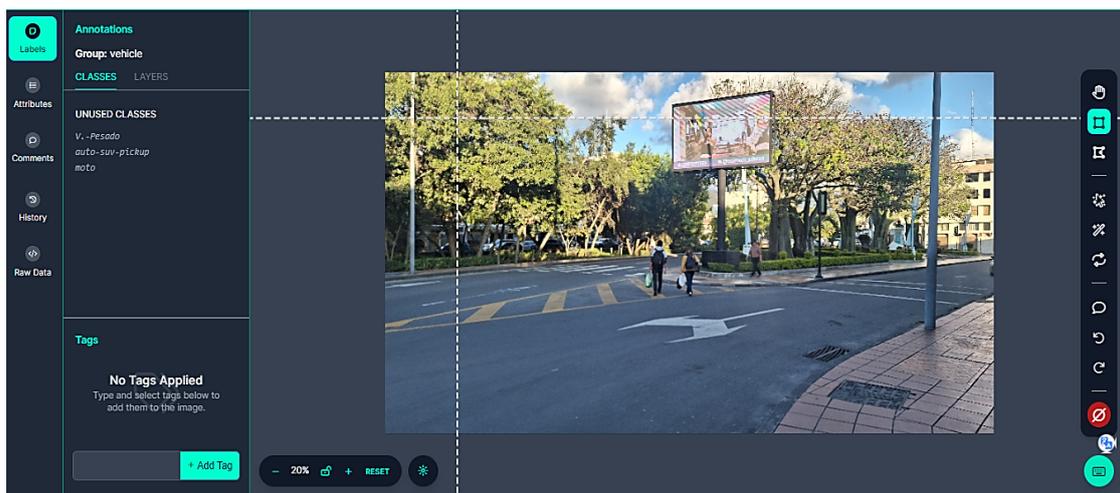
Proceso para Iniciar el Etiquetado del Conjunto de Datos.



El etiquetado se lo realizó en cada una de las imágenes existentes en la base de datos, incluyendo aquellas consideradas como backgrounds. El proceso fue simple, se encerró el vehículo en un recuadrado llamado bounding box y al finalizar, se eligió la etiqueta correspondiente al tipo de vehículo en cuestión. Las imágenes que no contenían vehículos, también fueron tomadas en cuenta debido a que YOLOv5 entrena de mejor manera cuando se le especifica que en este tipo de fotogramas no existen objetos a detectar. Roboflow tiene la función de establecer esta característica en las imágenes durante el etiquetado.

Figura 11

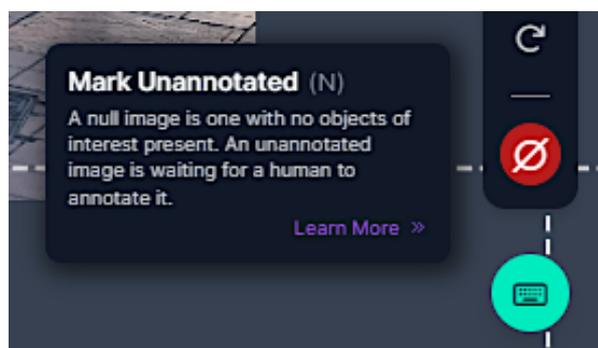
Interfaz de Roboflow con una Imagen Background.



En la figura 11, se observa una fotografía destinada para que funcione como background en la base de datos, esto quiere decir que en su contenido no existe ninguna de las clases de etiquetas que se está utilizando en el proyecto, por ello, en la parte inferior derecha se adjudicó la funcionalidad de “Mark Unannotated” para señalar su operatividad dentro del sistema.

Figura 12

Función de Mark Unannotated en Roboflow.

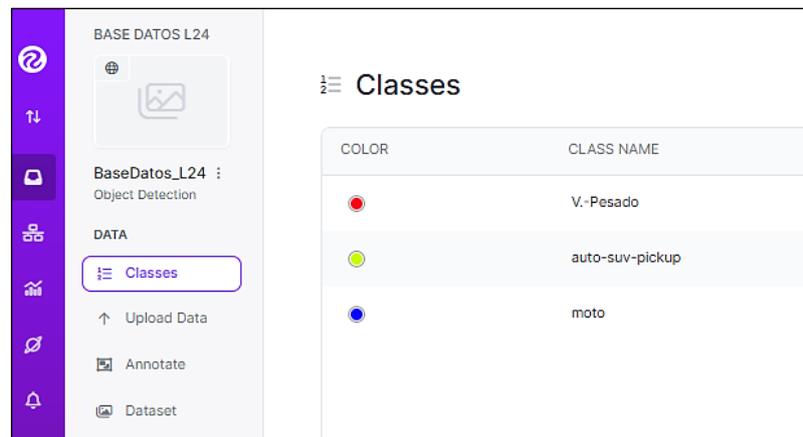


5.2.4 Clasificación de las etiquetas.

Para la clasificación del tipo de vehículos se contemplaron algunas opciones, sin embargo, tomando en cuenta las recomendaciones de otras investigaciones como (Moreira Ramos, 2021), el tamaño de los recuadros etiquetadores influyen a la hora de detectar cierto tipos de objetos, por lo tanto, la clasificación que se consideró más adecuada se estableció en 3 únicas clases con los tamaños de recuadros similares, Vehículos Pesados (V.-Pesados), auto-suv-pickup y moto.

Figura 13

Clasificación de Etiquetas en Roboflow.



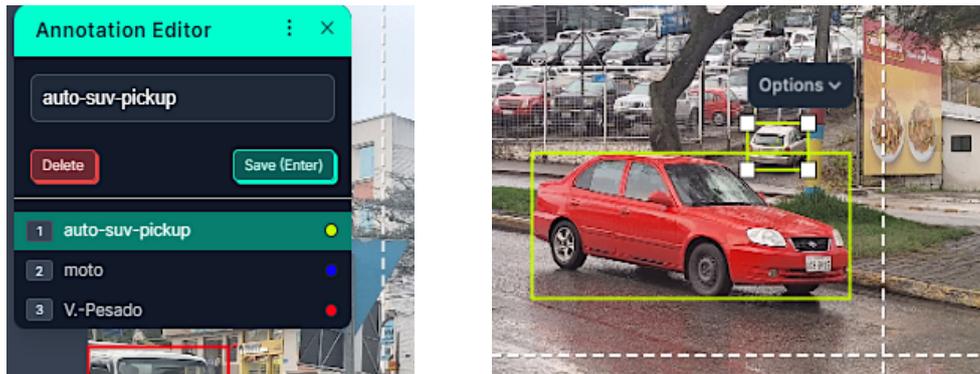
Se agruparon vehículos con características similares de la siguiente manera:

- **Auto-suv-pickup (clase 1):** en esta clase se consideraron todo tipo de automotor ligero y de uso utilitario (suv), autos particulares y camionetas.
- **Moto (clase 2):** toda clase de motocicletas ya sea a combustión o eléctricas.
- **V.-Pesados (clase 0):** todos aquellos vehículos que, debido a su tamaño, peso o robustez sea mayor al normal, como lo son autobuses, camiones, plataformas, tráilers, camiones cisterna, grúas, volquetas, busetas que superen los once pasajeros o camiones blindados.

Una vez se ha culminado el etiquetado de todas las clases existentes en la base de datos, que posean al menos un 50% del total físico del vehículo, se establece un porcentaje de división del 70% que se destinarán para el entrenamiento del modelo, y a su vez, el 30% restante para un proceso de validación del entrenamiento. Esto con el fin de establecer un formato de ordenamiento que requiere YOLOv5.

Figura 14

Etiquetado de Vehículos y Selección de Tipo de Etiqueta.



5.2.5 Creación de la base de datos.

La plataforma Roboflow crea archivos con extensión “.txt”, también llamados “labels”, junto con las imágenes etiquetadas una vez finalizado el proceso. Estos archivos contienen la clase de etiqueta, seguido de las coordenadas de las cuatro esquinas que tienen los recuadros existentes en la imagen. Además, el nombre de estos archivos de texto (.txt), debe ser el mismo al de su correspondiente imagen. Por lo tanto, en la base de datos existirán las fotografías tomadas, junto con sus “labels”.

Figura 15

Estructura de las Imágenes con su Correspondiente Etiqueta.

```
C:.\n├── images\n│   ├── imagen_1.jpg\n│   └── imagen_2.jpg\n└── labels\n    ├── imagen_1.txt\n    └── imagen_2.txt
```

Nota. Es imprescindible que el nombre de las imágenes y los “labels” tengan el mismo nombre. Mediante esta acción Yolo identifica los bounding boxes correspondientes a cada imagen.

La base de datos es la principal estructura del sistema para poder sustentar el proceso de entrenamiento con YOLOv5, donde el modelo aprenderá a detectar y clasificar vehículos con una precisión bastante elevada. El directorio tomó el nombre de “BD_2024_4” para el

conjunto de datos exportado desde Roboflow. Contiene la distribución de carpetas para el entrenamiento.

- **Train:** se designa el 70% del total de la base de datos final.
 - *Images:* imágenes destinadas para el entrenamiento.
 - *Labels:* etiquetas correspondientes a las imágenes de entrenamiento.
- **Val:** se establece el 30% del total de la base de datos final.
 - *Images:* imágenes destinadas para la validación del entrenamiento.
 - *Labels:* etiquetas correspondientes a las imágenes de validación.
- **data.yaml:** archivo que redireccionó a los directorios en el entrenamiento y señala el número y nombre de clases existentes.

Además, la calidad de las etiquetas y las posibles modificaciones son esenciales para que el modelo tenga un rendimiento óptimo. Finalmente, la base de datos se puede modificar para mejorar su exactitud y eficiencia en los modelos entrenados.

5.2.6 Aumento de datos.

Además, al finalizar el proceso de etiquetado, la misma plataforma ofrece la función de crear versiones de la base de datos. En estas versiones se le añadió argumentos y preprocesamientos antes de exportar el archivo “.zip” que contiene las imágenes con sus respectivas etiquetas. En la base de datos “BD_2024_4 se aplicaron las siguientes variantes:

- Preprocesamiento:
 - Auto Orient.
 - Resize 640x640.
- Argumentos:
 - Rotation -15° y +15°.
 - Grayscale 6%.
 - Blur: 1.2px, 1.6px y 1.7px.

Con estas variantes en la base de datos se produjeron copias aleatorias de las imágenes aplicando las mencionadas características. Con este proceso se obtuvo la base de datos final enriquecida para futuros entrenamientos. La misma se puede visualizar en el Anexo 1.

5.3 Configuración de parámetros y entrenamiento del modelo.

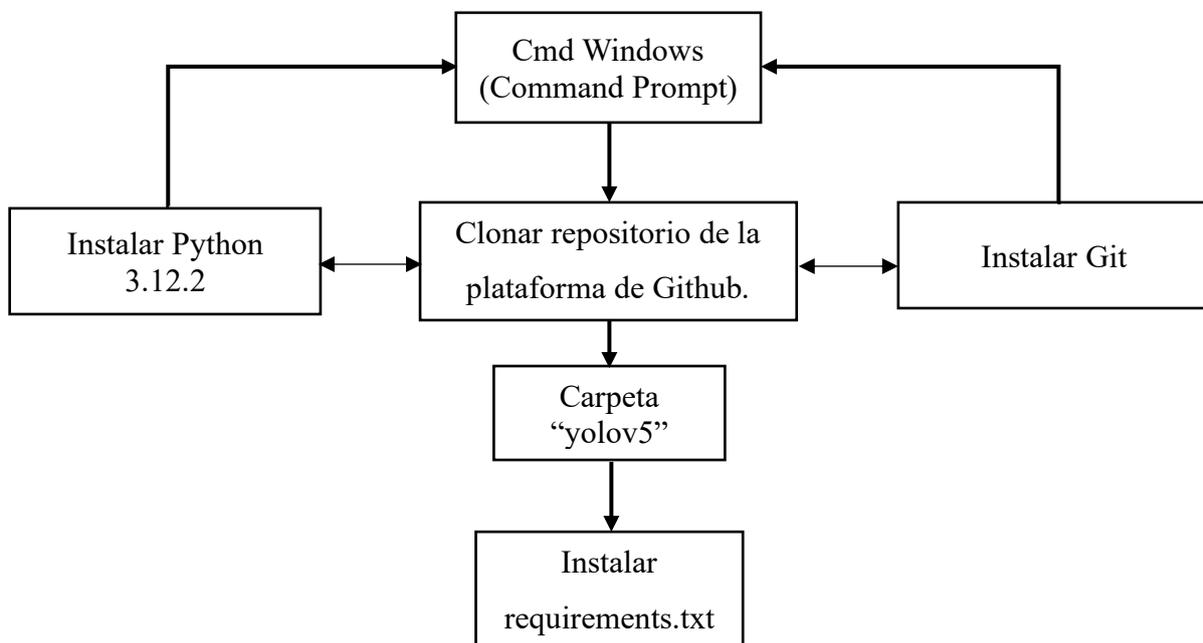
Previo al proceso de entrenamiento se debe instalar el repositorio de Yolov5 en la máquina computacional utilizada. Con la base de datos establecida en 3344 imágenes, para el proceso de entrenamiento con YOLOv5, es importante generar un orden de directorios previos al entreno. La estructura tiene que estar compuesta por dos carpetas principales (train y val), y dos carpetas adyacentes dentro de cada una de las carpetas principales, (images y labels). La carpeta “train” debe contener el 70% de imágenes y etiquetas correspondientes; así mismo, el 30% restante se lo destina a la carpeta “val”. También, se creó un archivo “.yaml” que conecta a Yolov5 con los directorios correctos de la base de datos y definirá las clases existentes en el modelo. Por otra parte, para ejecutar el entrenamiento se debe conocer algunos parámetros de la configuración que YOLO tiene en su sistema.

5.3.1 Instalación de YOLOv5.

Afortunadamente YOLOv5 tiene la versatilidad para ser instalado en múltiples sistemas operativos, para este proyecto se instaló el software en una computadora portátil marca Dell modelo Inspirion 14 con Windows 10 Pro. Para ello, se requiere acceder al repositorio de ultralytics/yolov5 en la plataforma Github (Ultralytics, Github, 2024). El procedimiento para la descarga e instalación de las dependencias de Yolov5 es rápida y sencilla, en el Anexo 2, se accede al link del repositorio.

Figura 16

Diagrama del Proceso de Instalación de YOLOv5 Mediante el Cmd (Command Prompt)

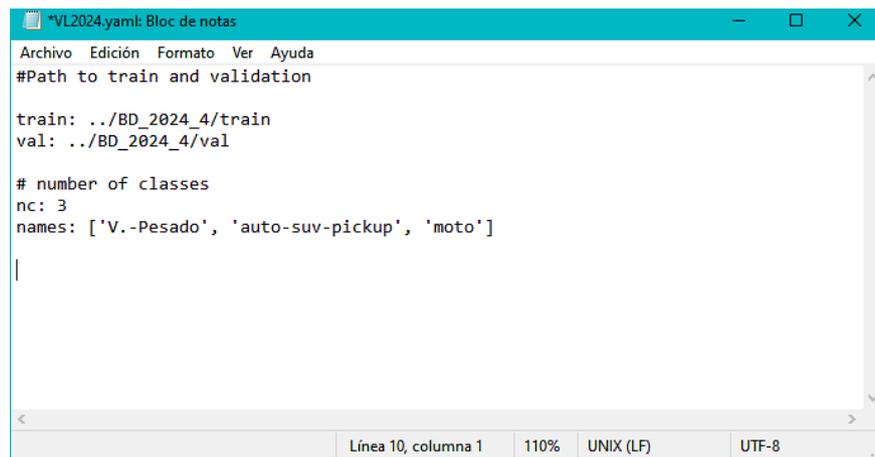


5.3.2 Elaboración del archivo .yaml

Simultáneamente, se creó un archivo de texto con la extensión “.yaml”, este archivo ayuda a YOLO durante el inicio del entrenamiento ya que indica los directorios exactos del conjunto de datos organizado. Cabe recalcar que el nombre del archivo es relativo, sin embargo, se lo estableció como “VL2024.yaml”. Su contenido se lo muestra en la siguiente ilustración:

Figura 17

Contenido del archivo VL2024.yaml



```
Archivo Edición Formato Ver Ayuda
#Path to train and validation

train: ../BD_2024_4/train
val: ../BD_2024_4/val

# number of classes
nc: 3
names: ['V.-Pesado', 'auto-suv-pickup', 'moto']

|

Línea 10, columna 1 110% UNIX (LF) UTF-8
```

Nota. Es importante establecer los directorios correctos de la base de datos, puesto que el funcionamiento del sistema se detiene al no encontrar las rutas. También se estableció las clases que se determinaron durante el etiquetado.

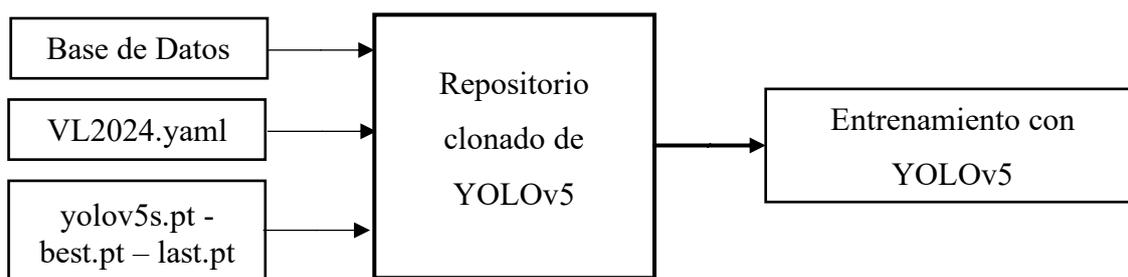
5.3.3 Entrenamiento con YOLOv5.

Con todo listo, se indagó en la página web oficial de (Ultralytics, docs.ultralytics.com, 2024), para acceder a la línea de comando, que iniciará el entrenamiento de YOLOv5 desde el Cmd de Windows, para ello se debe navegar hasta el repositorio clonado dentro del mismo intérprete. Esta línea ejecuta el script de Python “train.py” junto con algunos argumentos que especifican los parámetros con los que el sistema entrenará.

Como se mencionó anteriormente, los directorios y el archivo “.yaml” jugaron un papel clave para redireccionar a YOLO con los datos correctos, por lo tanto, la base de datos y el archivo “VL2024.yaml” fueron los promotores del inicio para establecer la siguiente secuencia que dio inicio a los entrenamientos. Para lograr el propósito de manera más firme en las detecciones, se utilizaron los pesos “yolov5s.pt” como base para algunos entrenamientos.

Figura 18

Diagrama de Organización para Entrenamiento en YOLOv5.



Al finalizar el primer entrenamiento de 50 épocas utilizando los pesos del “yolov5s.pt”, se repitió el proceso con otras 50 épocas con la misma base de datos, pero sin tomar en cuenta los pesos de Yolo, es decir, desde 0. Puesto que, al observarse los resultados del primer y segundo entrenamiento, se determinó que la base de datos debía ser mejorada, en cuanto a calidad de etiquetas y número de épocas respectivas. Al concluir los entrenamientos, se obtuvo información del rendimiento a través de métricas y “weights”, quienes muestran la eficiencia que el sistema aprendió a partir de la base de datos proporcionada. Básicamente, los pesos son el cerebro del sistema, por ello, el archivo “best.pt” guarda el punto del entrenamiento donde las métricas tuvieron mejor rendimiento, a diferencia de “last.pt”, que se usa para continuar entrenando. Posteriormente se iniciaron el tercer y cuarto entrenamiento que, tras la modificación de las etiquetas en la base de datos y aumento de la misma, se buscó obtener unos pesos que sean capaces de hacer predicciones precisas a la hora de contabilizar vehículos.

Tanto el tamaño de imagen y el número de batch se mantuvieron constantes debido a los recursos que se disponía para desarrollar todos los entrenamientos.

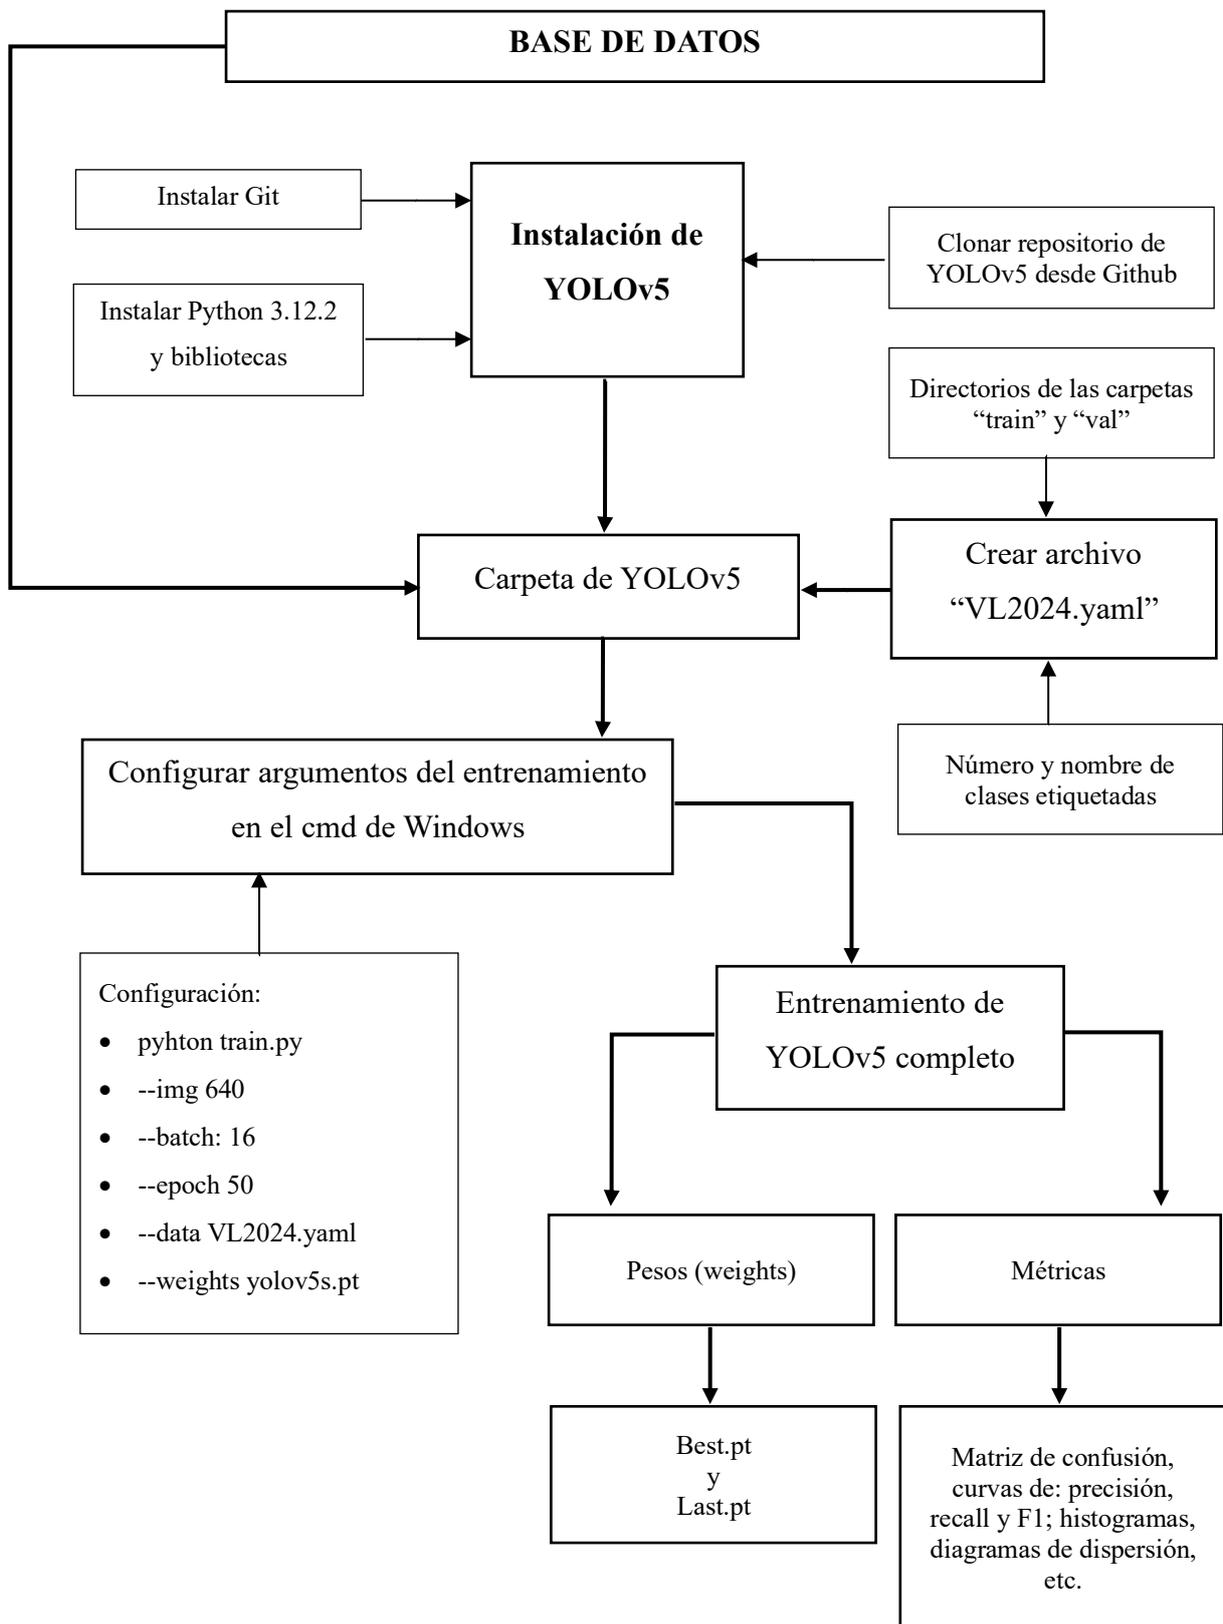
Tabla 3

Hiperparámetros Usados en los Entrenamientos.

Entrenamiento		--img	--batch	--epoch	--data	--weights
Nro. 1				51		yolov5s.pt
Nro. 2	python			51		0
Nro. 3	train.py	640	16	10	VL2024.yaml	yolov5s.pt
Nro. 4				50		yolov5s.pt

Figura 19

Diagrama de Flujo del Entrenamiento en YOLOv5.



5.4 Evaluación del modelo entrenado.

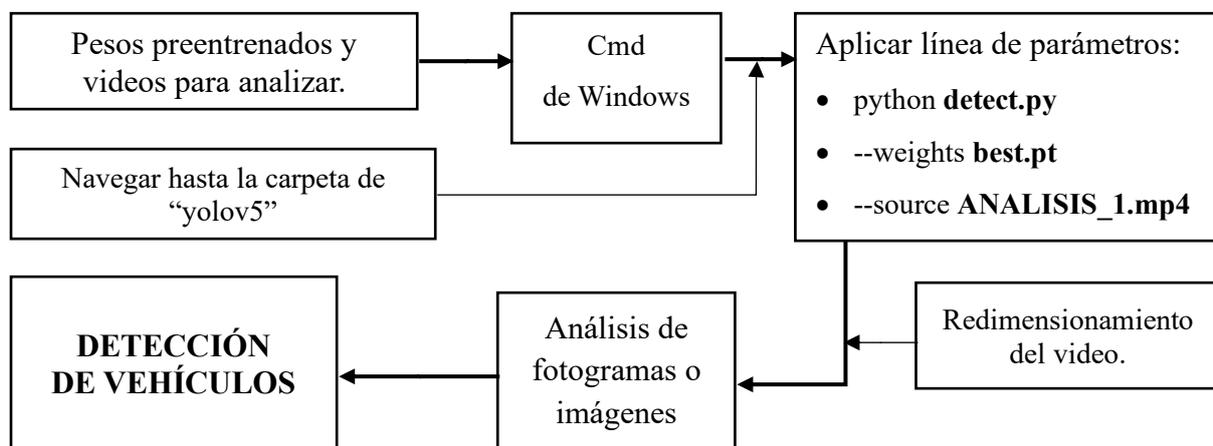
Los pesos obtenidos del tercer entrenamiento fueron los más eficientes, por lo que se pudo llevar a cabo una serie de pruebas que determinaron el rendimiento del modelo entrenado. Para lograr este propósito, se adjuntaron, en el repositorio de YOLOv5, los videos grabados con dron de la zona de interés. Los videos tienen establecido el nombre “ANALISIS_” seguido del número de prueba que le corresponde y el formato de video “.mp4”. Finalmente se genera un nuevo video con las detecciones en el repositorio “runs/detect”.

5.4.1 Parámetros para la detección vehicular.

Para lograr el objetivo, se obtuvo una serie de grabaciones de video y se adjuntaron imágenes relacionadas con el entorno analizado. Los archivos están en formato “.mp4”, “.jpg” y “.png”, con la finalidad de testear la versatilidad que tiene YOLOv5 a la hora de detectar archivos con diferente extensión. Para aplicar el comando de detección, obtenido desde a la página web oficial de (Ultralytics, 2024); se establecieron parámetros y desarrollaron los siguientes procesos:

Figura 20

Diagrama de Inicio a una Detección con Yolov5.

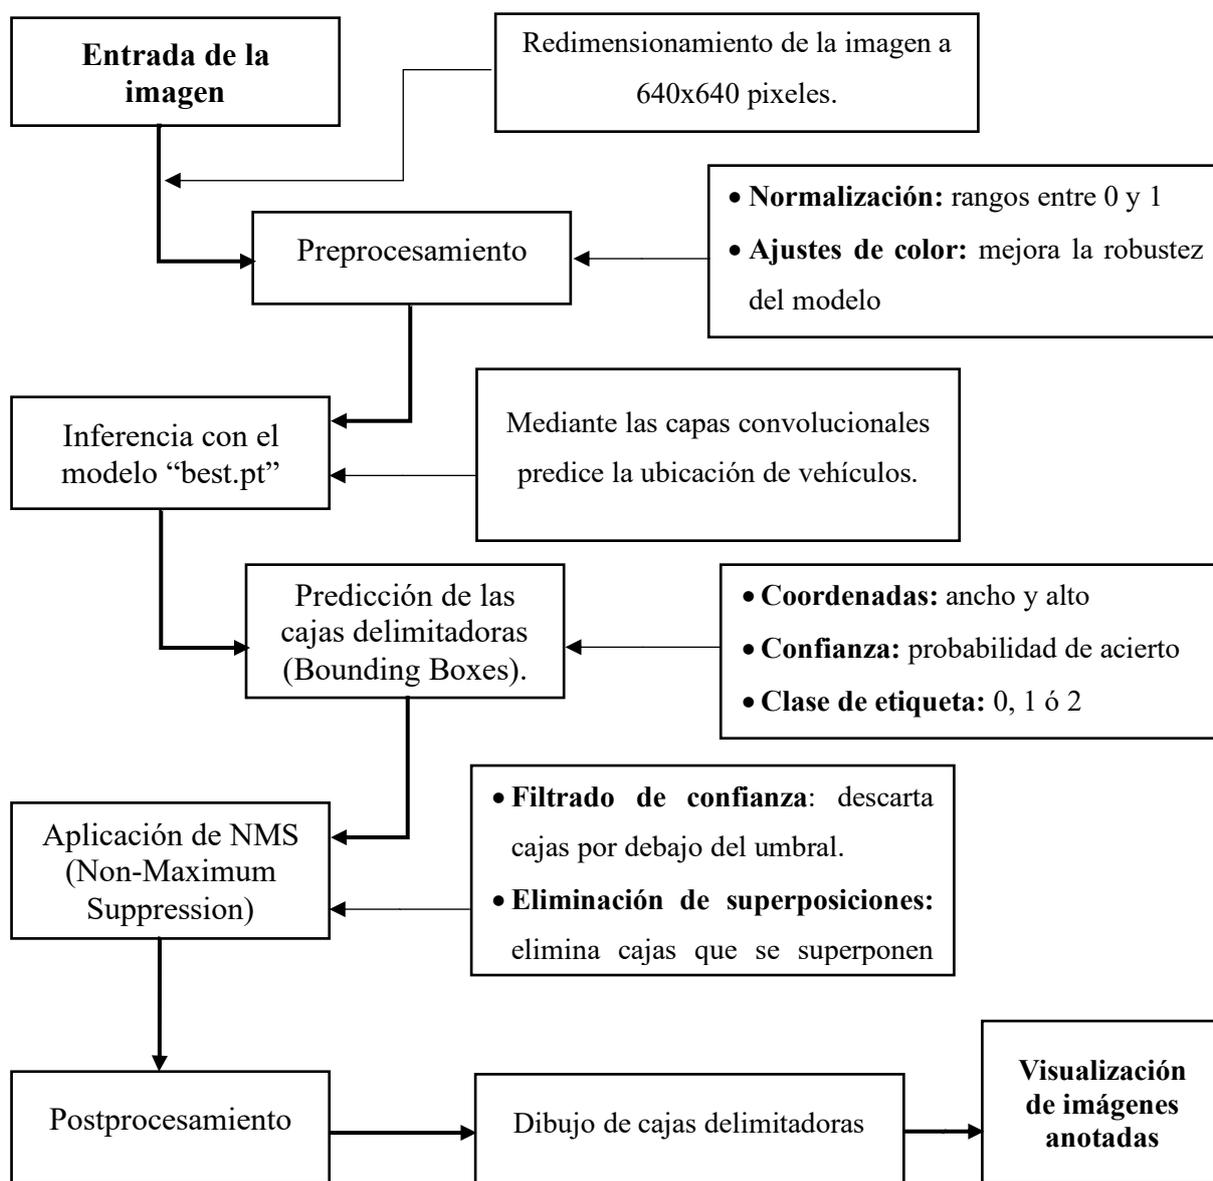


5.4.2 Puesta a prueba del modelo.

Con los parámetros establecidos, se empezó con el proceso de detección, para identificar vehículos dentro de una imagen; llegados a este punto, el sistema realiza una serie de pasos que se especifican en la figura 21.

Figura 21

Proceso de Detección en YOLOv5.



La detección de vehículos se obtiene de manera rápida, siempre y cuando los recursos informáticos lo faciliten, no obstante, YOLOv5 fue tan eficiente que con pocos recursos se obtuvo óptimos resultados. En la inferencia de los videos analizados con el modelo entrenado, se tomó cada uno de los fotogramas del video y se realizó el análisis, el tiempo de detección puede reducirse significativamente con ayuda de una unidad de procesamiento gráfico, GPU (Graphics Processing Unit), dado que la computadora utilizada no contaba con este componente, es lógico que los procesos demoren. Al final del procedimiento, el Cmd arroja un

archivo de video con las detecciones en el directorio clonado de YOLOv5, lo mismo ocurre cuando se analiza un lote o una sola imagen.

El proceso de realizar inferencias en nuevas imágenes es bastante sencillo desde el punto de vista aplicativo. Los resultados de esta prueba, son el inicio para llegar a determinar del flujo vehicular, puesto que el sistema funciona correctamente y tiene un alto porcentaje de acierto en la detección de vehículos. En el Anexo 2, se aprecia el código empleado para la detección.

5.5 Proceso de obtención del flujo vehicular con YOLOv5.

Culminada la obtención de datos, el entrenamiento y las pruebas para la detección de vehículos, se utiliza un entorno de desarrollo integrado como es PyCharm, el mismo que procesará la información elaborada por YOLOv5. Para ello, YOLO se encarga del proceso de detección, mientras el entorno de desarrollo integrado, IDE (Integrated Development Environment) contabilizó los vehículos que transitan por la zona de interés para luego, junto con el tiempo transcurrido, aplicar la fórmula matemática que determinará el objetivo planteado. Además, para establecer un resultado confiable del flujo vehicular, se realizó un conteo de vehículos manual, con el fin de comparar estos resultados y los que el sistema obtiene.

5.5.1 Creación del script principal

En primer lugar, es necesaria la instalación de PyCharm en el sistema operativo del equipo de cómputo, para ello se utilizó la página web oficial de (JetBrains, 2024). Ya instalada la IDE, se procedió a crear una carpeta de proyecto que contendrá el repositorio clonado de yolo5, junto con los pesos entrenados y el video que se analizará. Esta carpeta de proyecto que se nombró como “IR_5”, contendrá todos los scripts del proyecto.

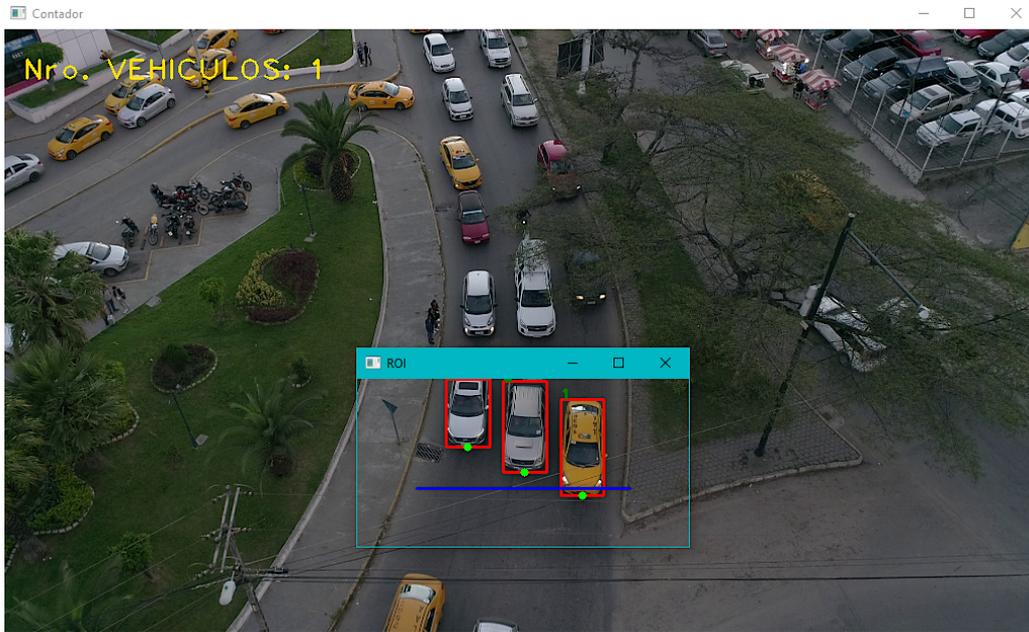
El script principal se lo denominó “COUNT.py”, ya que en él se desarrolla el proceso de detección y conteo con YOLOv5, en la misma, se importan las variables de los scripts secundarios que controlan el seguimiento de los vehículos, además de calcular del flujo vehicular al finalizar el video.

La variable “tracker”, dentro del script principal, hace el seguimiento de vehículos para ser contabilizados. Aquí fue necesario la creación de una región de interés o ROI (*Region of Interest*), dentro del video analizado, con el fin de optimizar los recursos y las detecciones a la hora de ejecutar el modelo con YOLO. La obtención de las coordenadas de la ROI se lo hace mediante otro script que provee de las coordenadas dentro del video. Obtenida la ROI, se dibuja una línea, que atraviesa esta zona específica por donde circulan los vehículos en los carriles

habilitados al tránsito. La función de esta línea es contabilizar cada una de las detecciones que capta Yolov5 y reflejar el conteo en la parte superior izquierda.

Figura 22

Frame de la Zona de Interés (ROI) con la Línea Contabilizadora.



Nota. Imagen captada durante el proceso de contabilización, donde se aprecia que un vehículo es contabilizado al momento de cruzar la línea dentro de la ROI.

5.5.2 Scripts auxiliares

La funcionalidad del script “tracker.py” es la de dar seguimiento, asignar y guardar una identificación única (IDs) a cada detección para que no sea contabilizada dos o más veces. La variable “Tracker” en el script “COUNT.py” es indispensable para la correcta contabilización de vehículos, también calcula el punto medio de los bounding boxes con la finalidad que sea un punto de referencia al entrar en contacto con la línea de conteo. Las líneas de código del script “COUNT.py” y “tracker.py” se las visualiza en el Anexo 4.

Una vez los vehículos han sido contabilizados, se inicia un segundo proceso para captar el tiempo de duración del video. El script principal ejecuta esta función, con la intención de que al finalizar la reproducción del frame de manera manual, este tome el tiempo de video transcurrido, y lo aplique en la formula del flujo vehicular junto con el número de vehículos captados hasta ese punto; del mismo modo, cuando la reproducción del frame finalizó por

completo, se captó el tiempo total del video en milisegundos para después ser transformados en minutos y en segundos con el mismo objetivo de ser aplicados en la fórmula.

La captación del tiempo se la dio en minutos y segundos por el motivo de demostrar que YOLOv5 puede ser aplicado en sistemas que son capaces de determinar el flujo vehicular, de una zona determinada, a partir de cualquier punto en el tiempo de análisis; no obstante, existe también la posibilidad captar el tiempo en horas, pero se necesitaría de procesos de detección mucho más largos.

Cuando el frame finalizó, entró en funcionamiento el script llamado “calculate_flow.py” quien posee las variables necesarias para el cálculo del flujo vehicular. Este script mostró una ventana emergente una vez finalizó el análisis. En la ventana, se evidencia el tiempo de duración del video y los vehículos contabilizados; para finalmente aplicar la fórmula del flujo vehicular. El repositorio completo de este proyecto se lo puede encontrar a través del perfil personal en la plataforma GitHub, (Sarango, 2024). Anexo 4.

5.5.3 Cálculo del flujo vehicular

Con los datos del tiempo y número de vehículos captados, justo al finalizar el proceso de detección, se obtuvo un archivo llamado “result_data.pkl” quien contuvo estos datos de manera numérica para que el script “calculate_flow.py” realice las operaciones matemáticas correspondientes dentro de la fórmula del flujo vehicular. Dando como resultados, en un último frame, la información calculada del flujo en vehículos/minuto y vehículos/segundo. Se recalca también que se aplicó el análisis completo, a los siete video grabados con dron, de manera manual y aplicando el sistema Yolov5; resultando así una comparativa de la eficacia que tiene el modelo con respecto al 100% de vehículos que puede detectar un humano. El número de análisis realizados se vio limitado por la duración de la batería del dron, no obstante, se lograron captar las suficientes filmografías para llevar a cabo un análisis de este tipo.

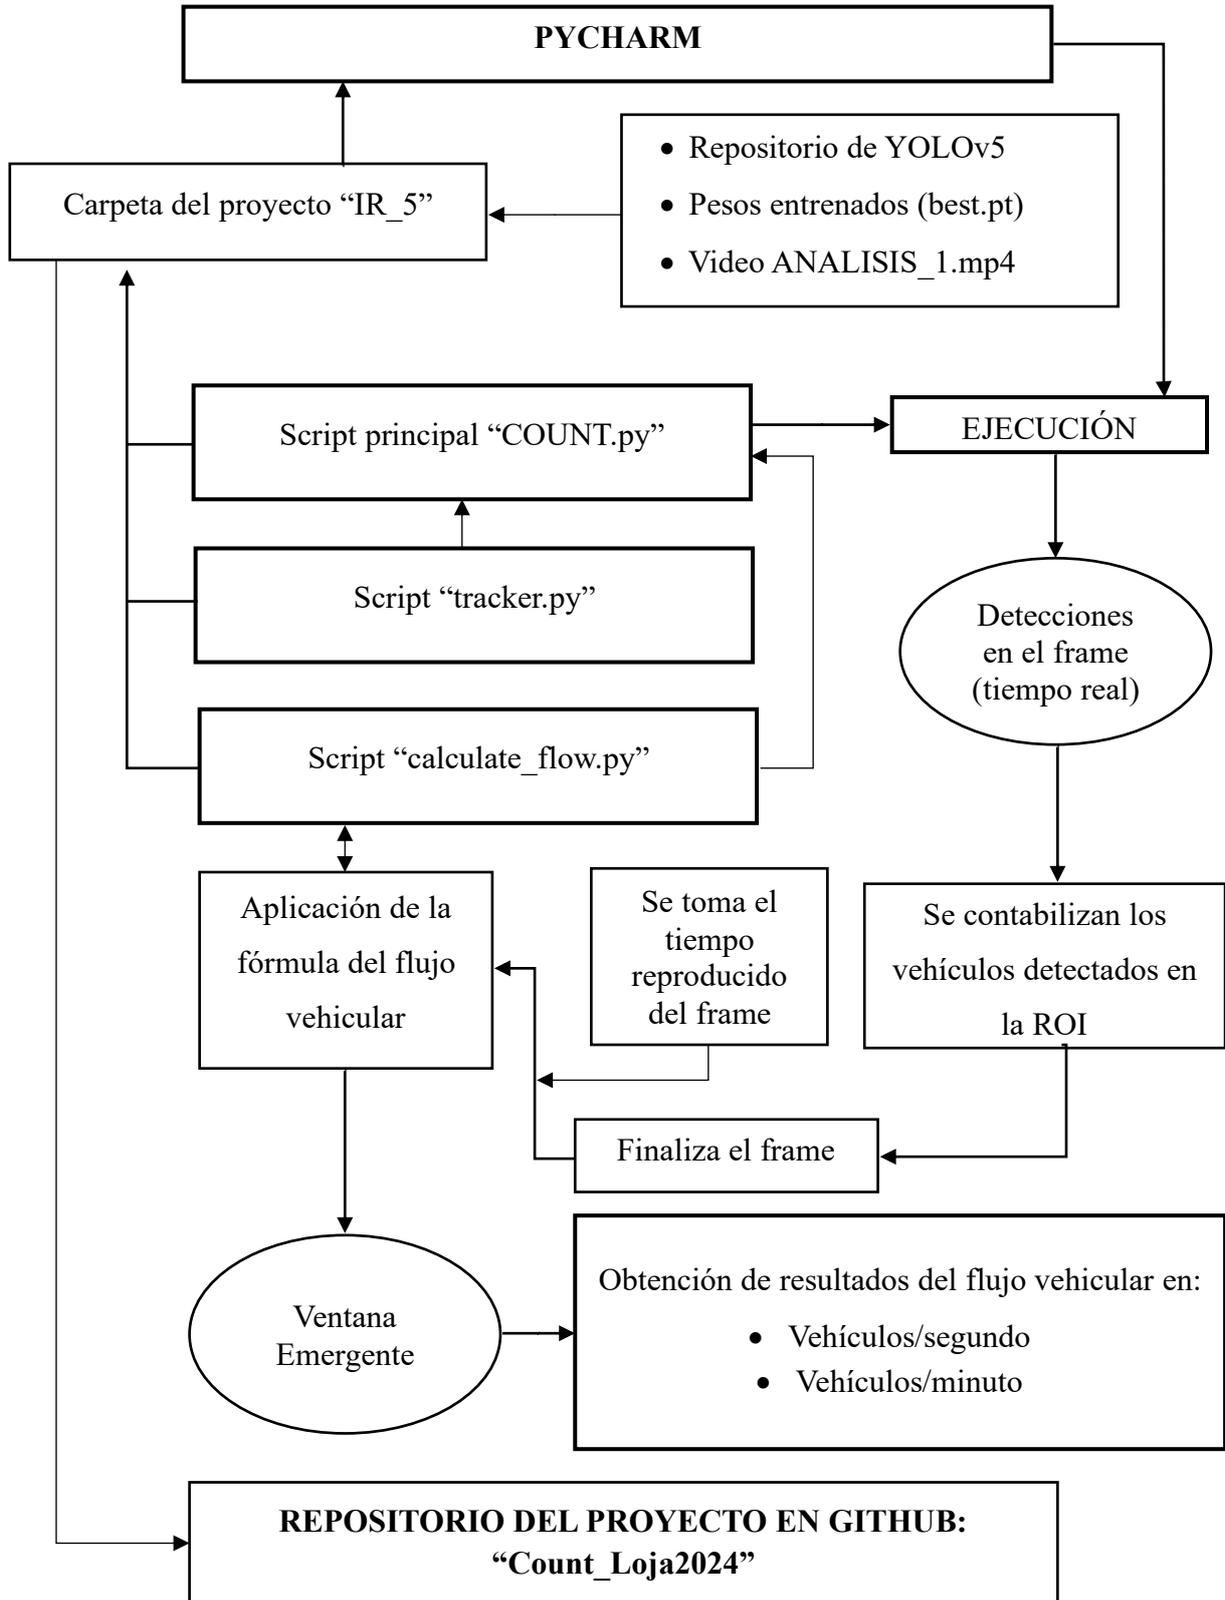
Los resultados obtenidos fueron satisfactorios, dando a conocer el importante flujo vehicular que transita por una de las vías de acceso más importantes de la ciudad. Demostrando que la aplicación de YOLOv5 es una alternativa muy confiable para la captación y procesamiento de datos aplicados en el estudio que promueve soluciones a los problemas generados en la circulación de vehículos de la zona.

A pesar de que el sistema creado es capaz de determinar el flujo vehicular, existen variables y elementos del flujo de tránsito que pueden ser calculados modificando el código fuente del script principal y añadiendo más scripts auxiliares, sin embargo, debido a los objetivos planteados, no se tomaron en cuenta en esta ocasión.

5.5.4 Síntesis de la obtención del flujo vehicular

Figura 23

Resumen del Proceso para Obtener el Flujo Vehicular.



6. Resultados

Durante el desarrollo de los métodos aplicados para la obtención del flujo vehicular se obtuvo una serie de datos e información relevante para la investigación, que ayudaron a cumplir con los objetivos planteados. Los resultados muestran la capacidad de YOLOv5 para producir datos de gran precisión en tiempo real, ofreciendo una valiosa herramienta para la planificación urbana y la gestión del tráfico en la ciudad de Loja.

6.1 Conjunto de datos recopilados.

En base a la metodología aplicada, los resultados obtenidos fueron satisfactorios ya que se logró obtener una base de datos completa y eficiente con la plataforma Roboflow y que, además, se familiariza con el entorno puesto a estudio.

6.1.1 Bases de datos obtenidas.

La extensa base de datos es el producto de aplicar el método de toma de muestras en periodos de 5 minutos con descanso de 10 minutos, es decir:

$$\begin{aligned} 30 \text{ img} \times \text{min} &\rightarrow \text{en 1 periodo de 5min} = 150 \text{ img} * \text{periodo} \\ 1\text{h} &\text{tendría 4 periodos de 5 minutos con descanso de 10 minutos} \\ \therefore 1\text{h}30 \text{ min} &= 6 \text{ periodos} \wedge 2\text{h} = 8 \text{ periodos} \end{aligned}$$

Tabla 4

Cantidad de Imágenes Obtenidas en las Semanas Impares del Mes.

SEMANAS IMPARES			
Día	Hora	Periodos	Cantidad imágenes
Lunes	7h00–8h30	6	900
	12h00–14h00	8	1 200
	18h00–19h30	6	900
Miércoles	7h00–8h30	6	900
	12h00–14h00	8	1 200
	18h00–19h30	6	900
Viernes	7h00–8h30	6	900

12h00-14h00	8	1 200
18h00-19h30	6	900
TOTAL, POR SEMANA		9 000
TOTAL, SEMANAS IMPARES		18 000

Tabla 5

Cantidad de Imágenes Obtenidas en las Semanas Pares del Mes.

SEMANAS PARES			
Día	Hora	Periodos	Cantidad imágenes
	7h00-8h30	6	900
Domingo	12h00-14h00	8	1 200
	18h00-19h30	6	900
TOTAL, POR SEMANA			3 000
TOTAL, SEMANAS PARES			6 000

Tabla 6

Cantidad de Imágenes Obtenidas en los Feriados del Mes.

FERIADOS (Desde 15 de enero al 15 de febrero)			
Día	Hora	Periodos	Cantidad imágenes
	7h00-8h30	6	900
Lunes 12-02-24	12h00-14h00	8	1 200
	18h00-19h30	6	900
	7h00-8h30	6	900
Martes 13-02-24	12h00-14h00	8	1 200
	18h00-19h30	6	900
TOTAL, FERIADO			6 000

Tabla 7*Cantidad Total de Imágenes Obtenidas en el Mes.*

TOTAL (Desde 15 de enero al 15 de febrero 2024)	
Semanas	Imágenes
TOTAL, SEMANAS IMPARES	18 000
TOTAL, SEMANAS PARES	6 000
TOTAL, FERIADO	6 000
TOTAL, BASE DE DATOS	30 000

Durante la preselección de imágenes, la base de datos quedó reducida de manera notoria puesto que se extrajo una muestra aleatoria del 10% del total, quedando así, una cantidad de 3000 imágenes organizadas según los requerimientos de Yolo.

Tabla 8*Reducción de la Base de Datos Principal.*

Conjunto	Imágenes
BASE DE DATOS PRINCIPAL	30 000
REDUCCIÓN (90%)	27 000
BASE DE DATOS SECUNDARIA (10%)	3 000

Debido a los recursos limitados, esta reducción es importante para no saturar al sistema en el entrenamiento del modelo que se desea obtener. Dado este antecedente, se realizó otra exhaustiva distinción de imágenes de la base de datos secundaria, con el propósito de establecer un conjunto de datos cercano a los mil fotogramas. Para esta clasificación se tomó en cuenta los numerosos tipos de vehículos que se visualizan, además de fotos en las que no exista ninguna clase de vehículo.

Tabla 9*Reducción de la Base de Datos Secundaria a Base de Datos Final.*

Conjunto de datos	Imágenes
BASE DE DATOS SECUNDARIA	3 000
REDUCCIÓN	1 177
BASE DE DATOS FINAL	1 823

Con la base de datos final establecida se pudo continuar con el etiquetado de la misma para los entrenamientos que se realizaron posteriormente.

6.1.2 Base de datos etiquetada.

Durante la creación de la primera base de datos, se procedió al etiquetado en la plataforma Make Sense, sin embargo, esto ayudó a iniciar la comprensión del proceso de etiquetado en las imágenes obtenidas. Make Sense se recomienda utilizar en proyectos que involucren bases de datos pequeñas. Puesto que se usó Roboflow, se aplicaron argumentos al final del etiquetado que hicieron que la base de datos aumente.

Tabla 10*Aumento de la Base de Datos.*

Conjunto de datos	Imágenes
BASE DE DATOS FINAL	1 823
BASE DE DATOS FINAL CON ARGUMENTOS	3 344

La base de datos final se la puede obtener directamente en la plataforma de Roboflow, bajo el enlace agregado en el Anexo 1, es de uso público y aplicable en múltiples sistemas de detección de objetos. Mediante la obtención de la base de datos con argumentos, dio pie a continuar con el proyecto propuesto. Fue sin duda, una de las partes fundamentales del desarrollo ya que, en base a esta información, el cerebro del proyecto aprendió a detectar vehículos con mayor eficacia.

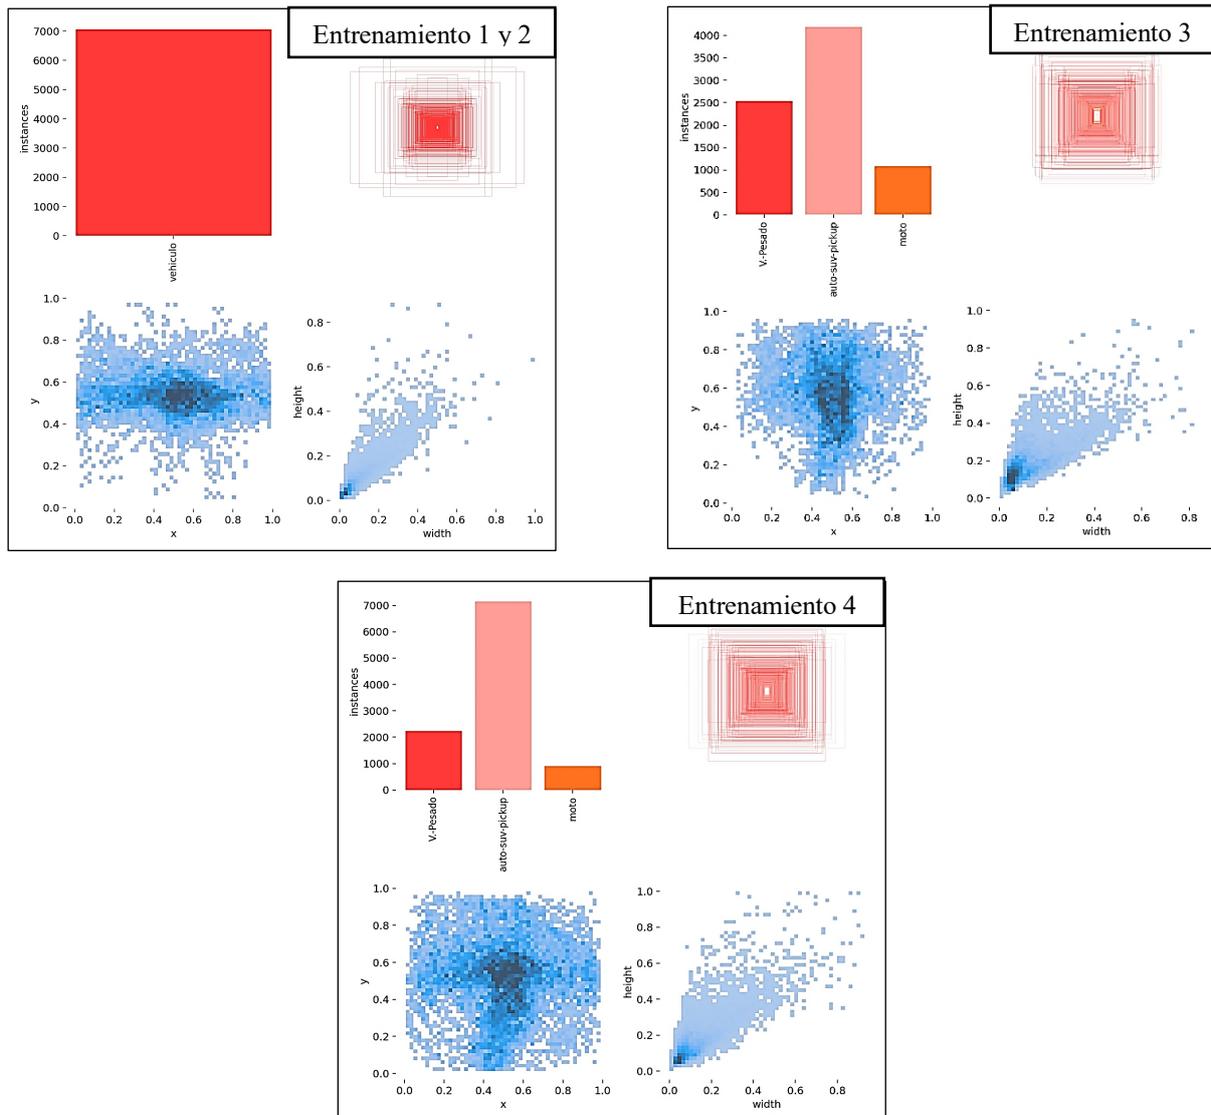
6.2 Métricas producto de los entrenamientos con YOLOv5

Con el conjunto de datos etiquetados se inició el proceso de entrenamiento con el sistema YOLOv5. La preparación del cerebro capaz de detectar vehículos fue sumamente importante para determinar la eficacia que este tendrá a la hora de realizar nuevas inferencias.

6.2.1 Conjunto de datos etiquetados.

Figura 24

Conjunto de Datos Etiquetados.



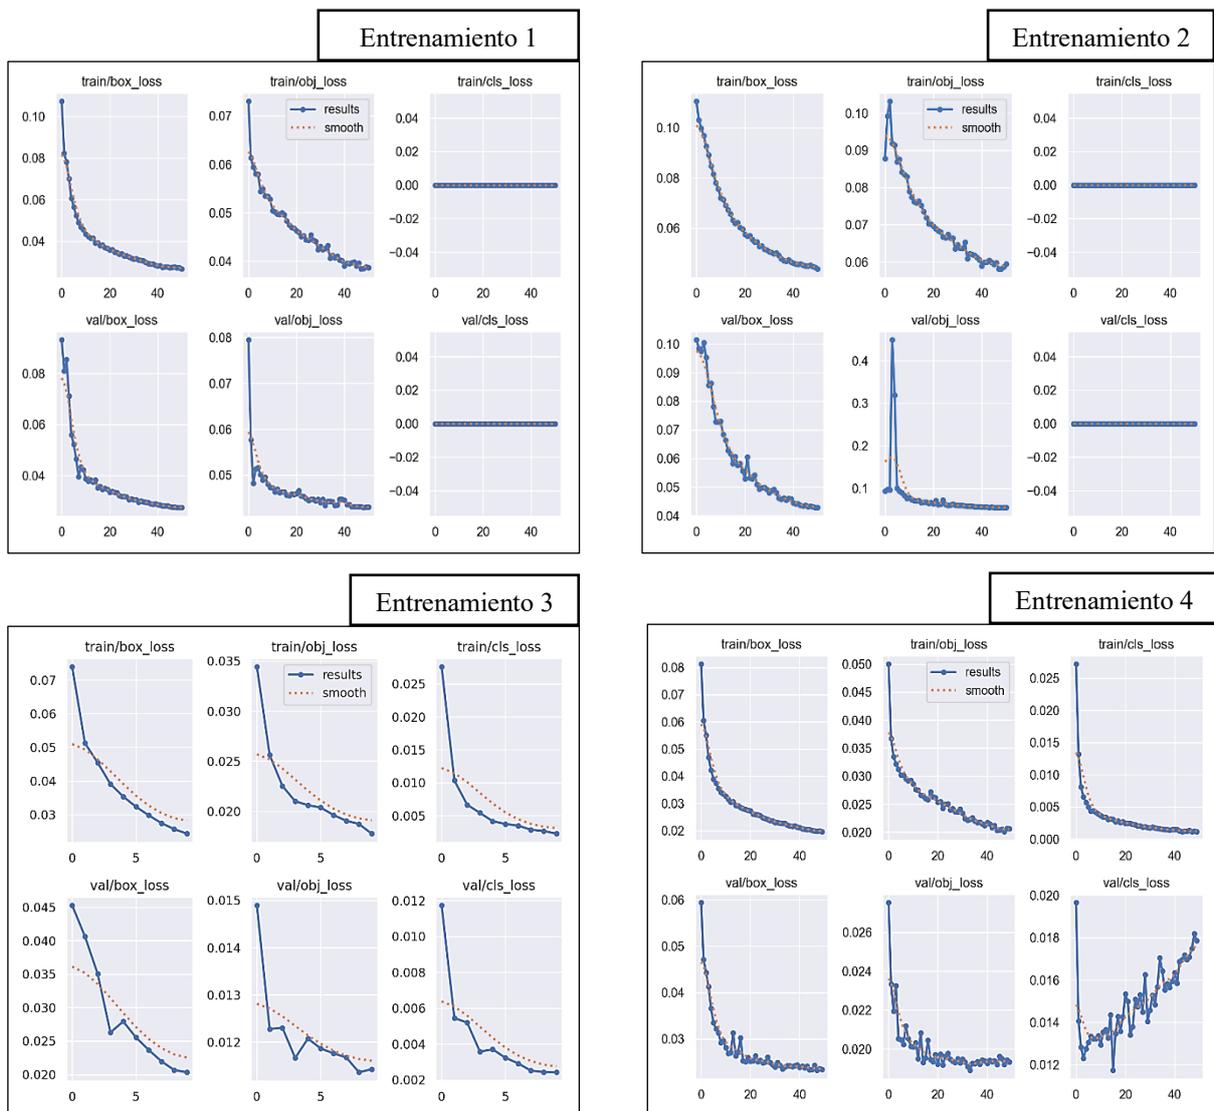
En los dos primeros entrenamientos se aprecia una sola etiqueta de vehículo, puesto que se determinó que el sistema detectaba de mejor manera clasificándolos, se puede observar que en los entrenamientos 3 y 4 los automotores más frecuentes son de tipo ligero (autos, vehículos

suavizado y pickups). También los gráficos de dispersión muestran que la mayoría de etiquetas realizadas se sitúan en el centro de las imágenes y en su mayoría los bounding boxes son de tamaño pequeño.

6.2.2 Pérdidas en los procesos de entrenamiento y validación.

Figura 25

Gráficas de la Pérdida en Cajas Delimitadoras.



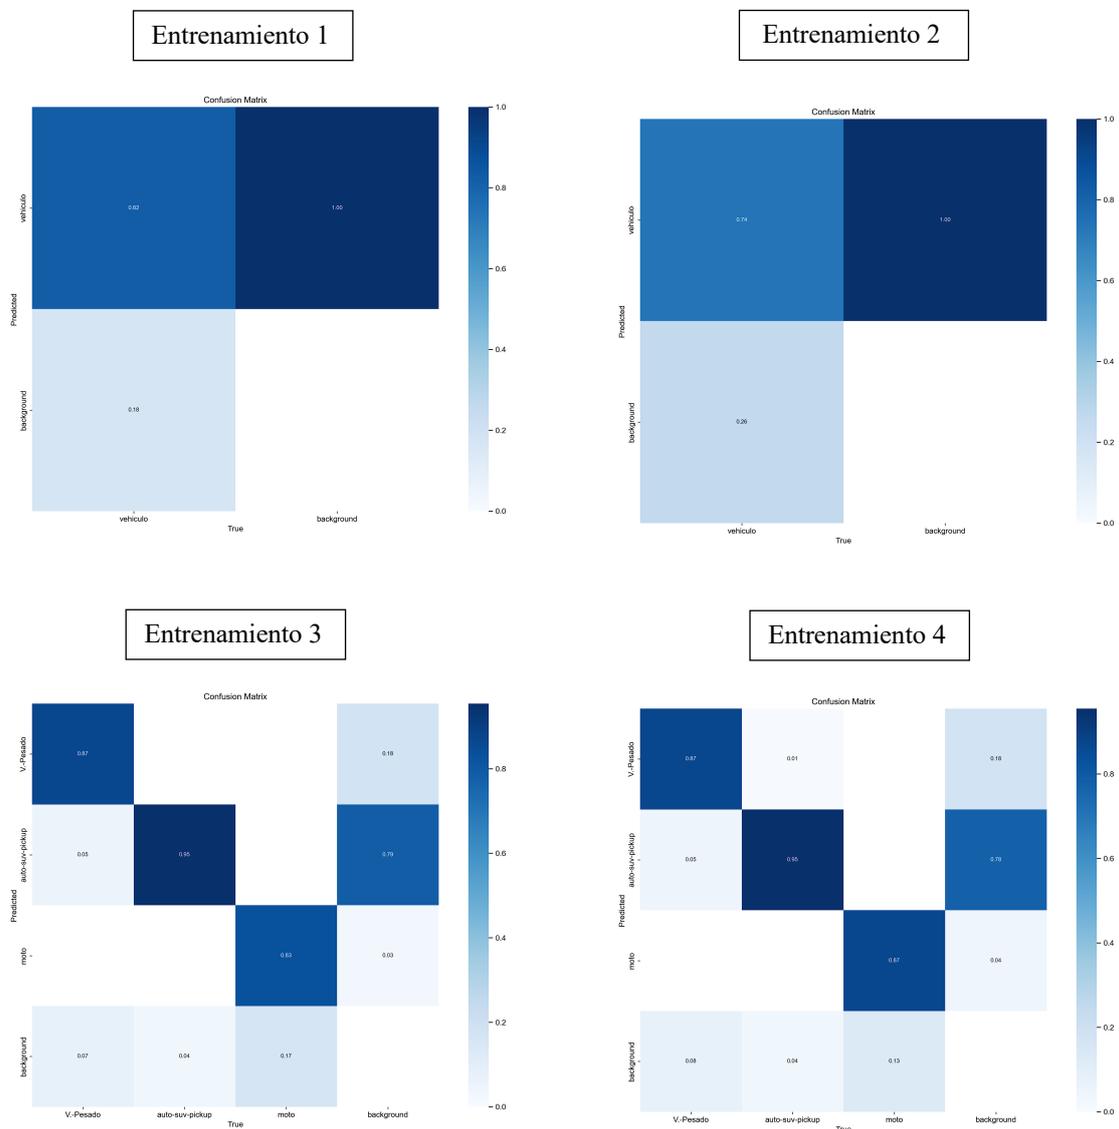
Los primeros tres entrenamientos muestran una disminución en pérdidas progresivas de las etiquetas durante los procesos de entrenamiento y validación, lo que da a entender que el sistema se adapta de manera correcta al propósito. No obstante, el último entrenamiento marca una elevada pérdida en el proceso de validación lo que demuestra que existe un sobreajuste en

el número excesivo de épocas de entrenamiento. Sin duda el tercer entrenamiento es el que menor índice de pérdidas representa, debido a la suavidad de las curvas.

6.2.3 Matriz de confusión

Figura 26

Matrices de Confusión de los Entrenamientos Realizados.



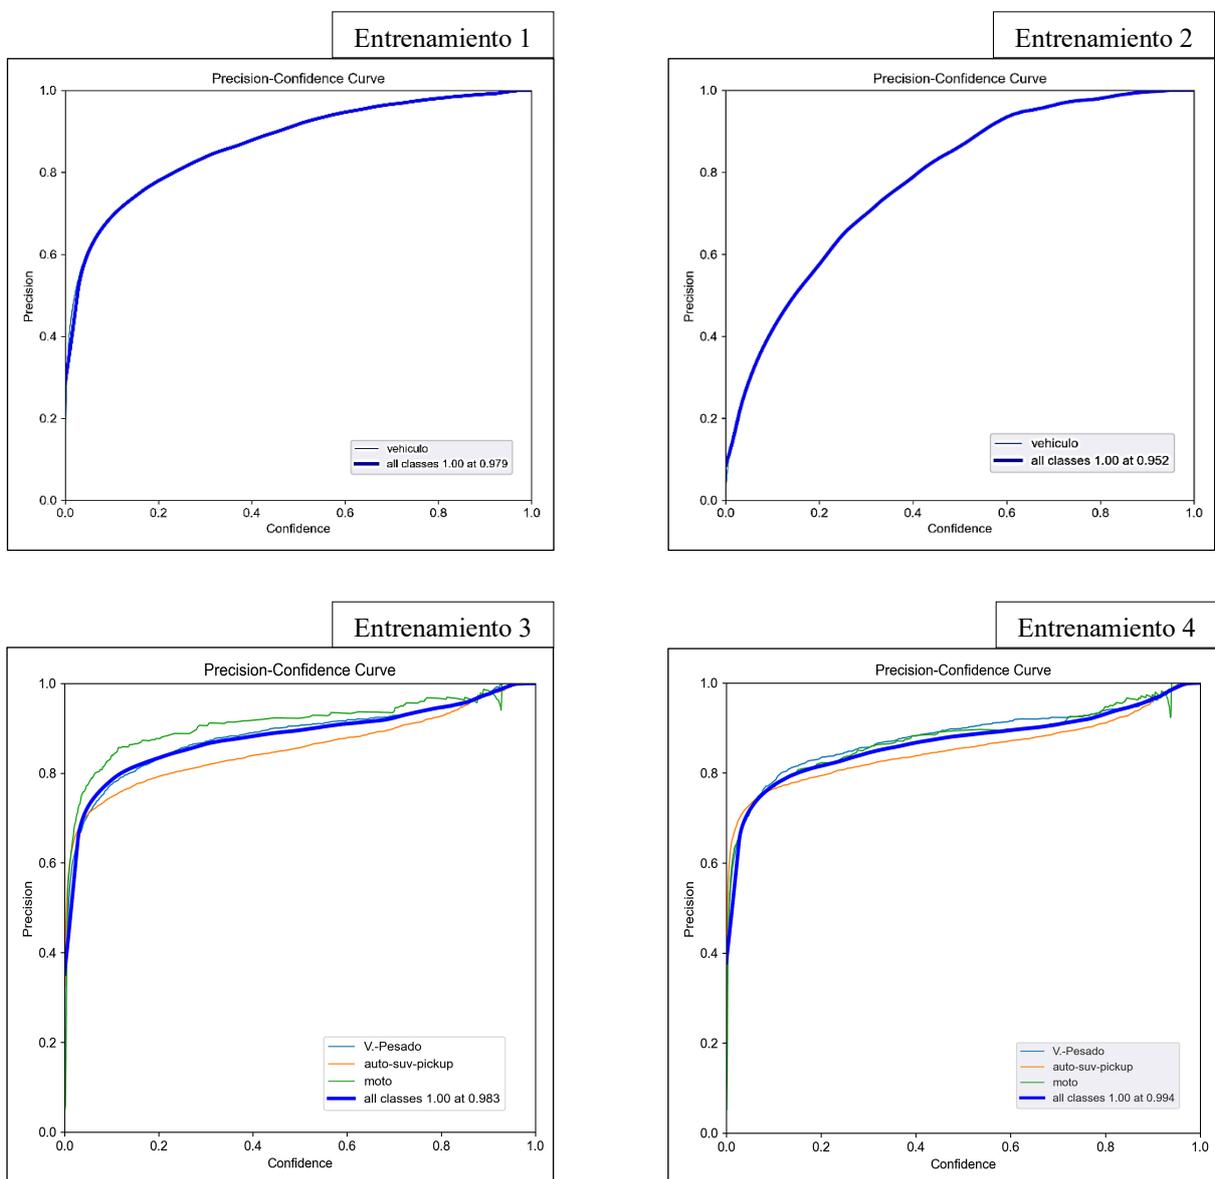
Los entrenamientos 1 y 2 fueron capaces de obtener un 82% y 74% de precisión en los verdaderos positivos (VP), con escasos falsos positivos (FP) y falsos negativos (FN), (18% y 26%) a la hora de clasificar y comparar vehículos con el fondo, sin embargo, el background es el mayor desafío que enfrenta el sistema, puesto que los FP y FN generados, ascienden hasta el 100% durante la validación del entrenamiento, esto revela que el sistema detecta vehículos donde no existen. Lo que no sucede en los entrenamientos 3 y 4, los mismos que presentan un

elevado porcentaje de precisión en los VP, siendo la clase de vehículos ligeros la más acertada en las predicciones con un 95% de acierto y, las motos, la clase menos precisa con un 83% al 87%. Además, la matriz presenta un porcentaje muy reducido de FP y FN en la mayoría de las comparaciones; a excepción de los vehículos ligeros que al compararse con el background presenta un porcentaje considerable de FP y FN (79% y 78%, respectivamente) que, sin duda, es un avance importante ya que en los primeros dos entrenamientos este era del 100%. El aumento de la base de datos y la clasificación de vehículos ayudó a reducir este tipo de errores durante las predicciones. Las casillas en blanco representan la inexistencia de errores al clasificar una clase de vehículo con otra durante el proceso de entrenamiento.

6.2.4 Precisión obtenida.

Figura 27

Gráficas de la Precisión Alcanzada en los Entrenamientos.

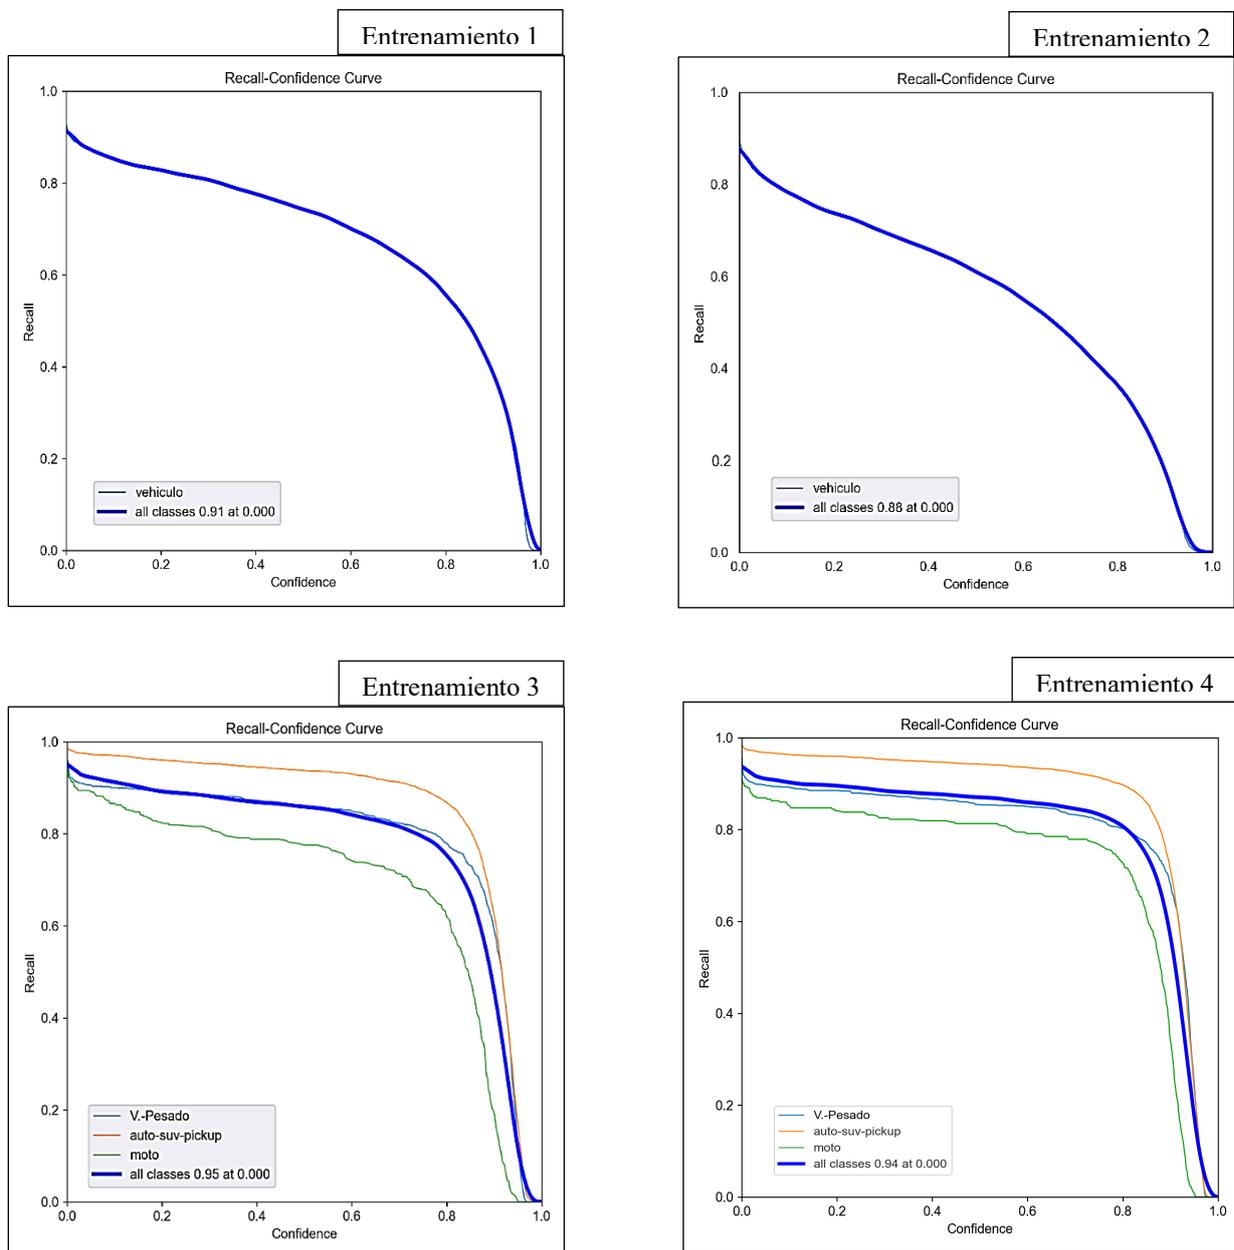


Dado que los dos primeros entrenamientos fueron muy parecidos en configuración de parámetros, es notable que las gráficas sean similares. El nivel de precisión es bastante alto con algunas dificultades en los niveles bajos de confianza, pero con progresión constante. Por otro lado, en los entrenamientos 3 y 4 mantienen un rendimiento alto en las diferentes clases de vehículos a lo largo de todos los umbrales generados, dando hasta un 99,4% de precisión promedio de todas las clases en el cuarto entrenamiento. Esto es un indicio claro que la base de datos generó un aprendizaje de alto valor.

6.2.5 Recall

Figura 28

Gráficas de Recall Obtenido.

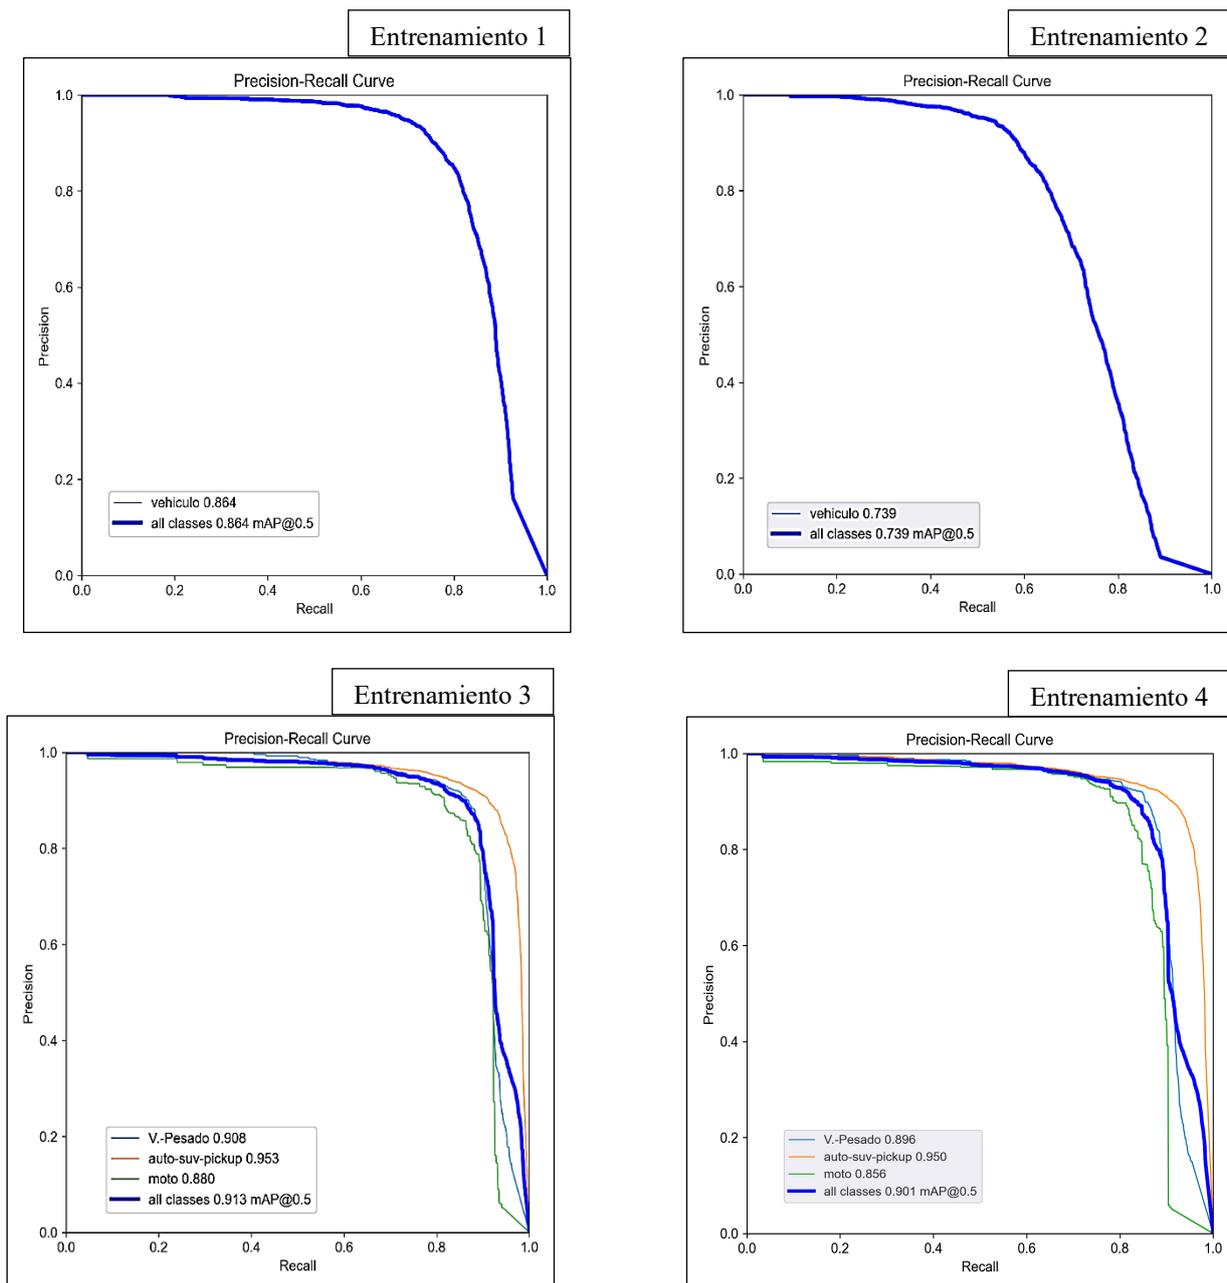


Los resultados obtenidos en los entrenamientos 1 y 2 sacrifican recall a medida que el umbral de confianza aumenta, sin embargo, se mantiene muy constante durante todo el entrenamiento. En los siguientes dos entrenamientos, se determina un 95% de recall en el promedio de todas las clases. Los vehículos pesados destacan por su alto nivel en umbrales de confianza elevados.

6.2.6 Relación entre la precisión y recall

Figura 29

Gráficas de la Relación entre Precisión y Recall.

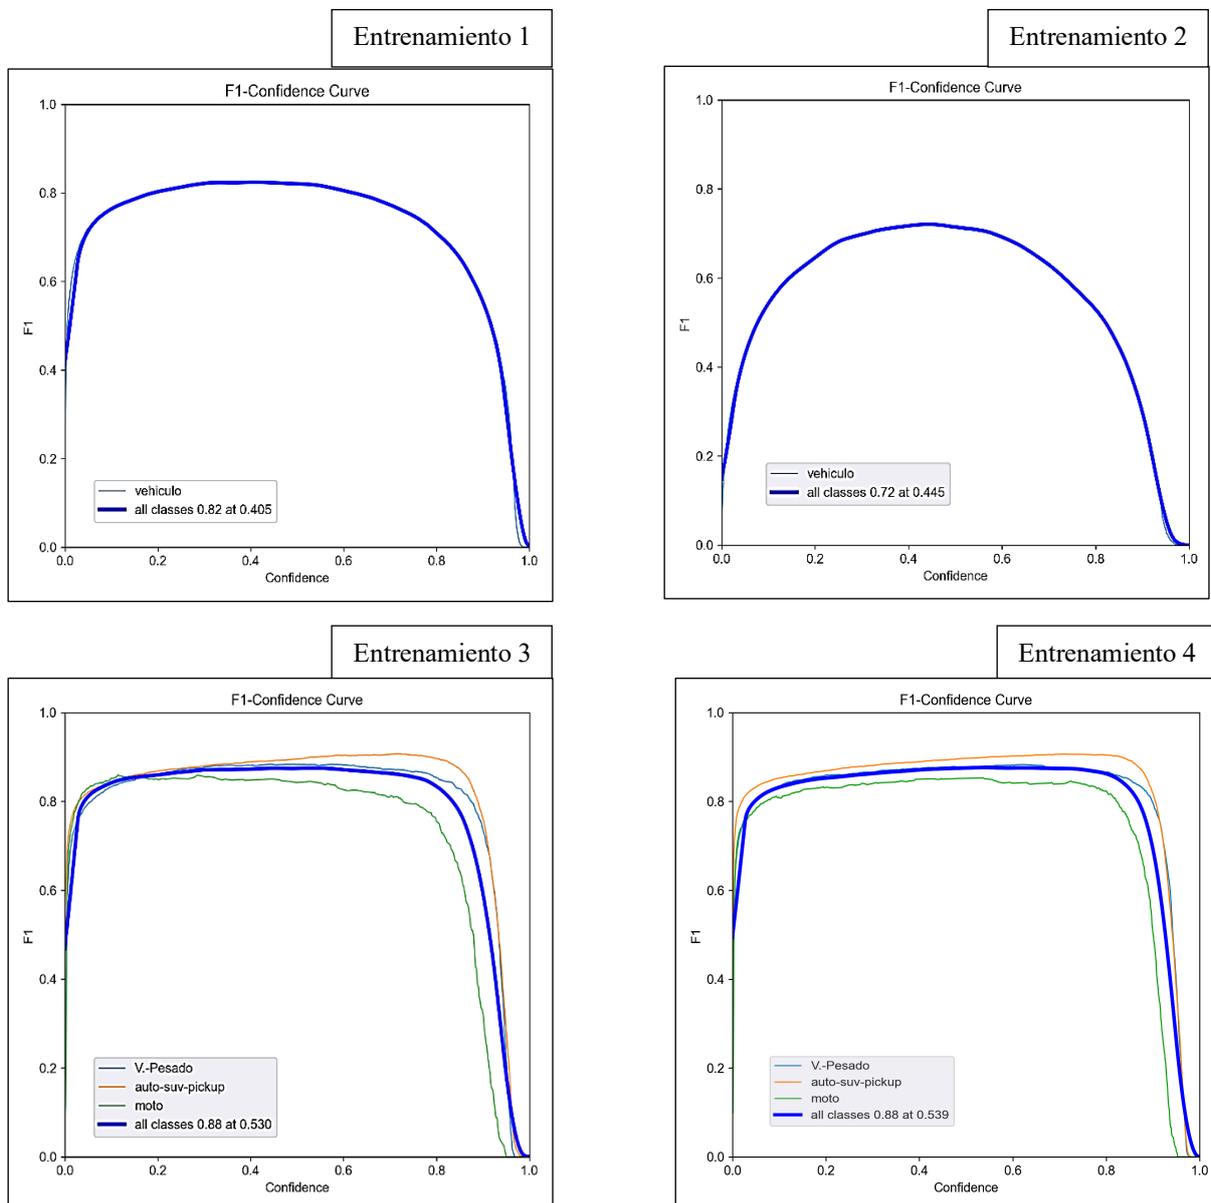


La precisión de los modelos entrenados con respecto al nivel de recall reflejan una constancia a lo largo de todo el entrenamiento de los modelos 1 y 2, destacando el segundo entrenamiento por tener un mejor balance que el primero. En los entrenamientos posteriores gozaron de una elevada precisión, presentando dificultades en la detección de vehículos ligeros; esto se debe al tamaño parecido de los bounding boxes con algunos vehículos pesados detectados en distancias más alejadas. No obstante, los valores del mAP-50 tienen un excelente nivel, alcanzando un 91,3% de promedio en todas las clases, obteniendo equilibrio entre precisión y recall en las tres clases.

6.2.7 Curva F1

Figura 30

Gráficas de la Curva F1.

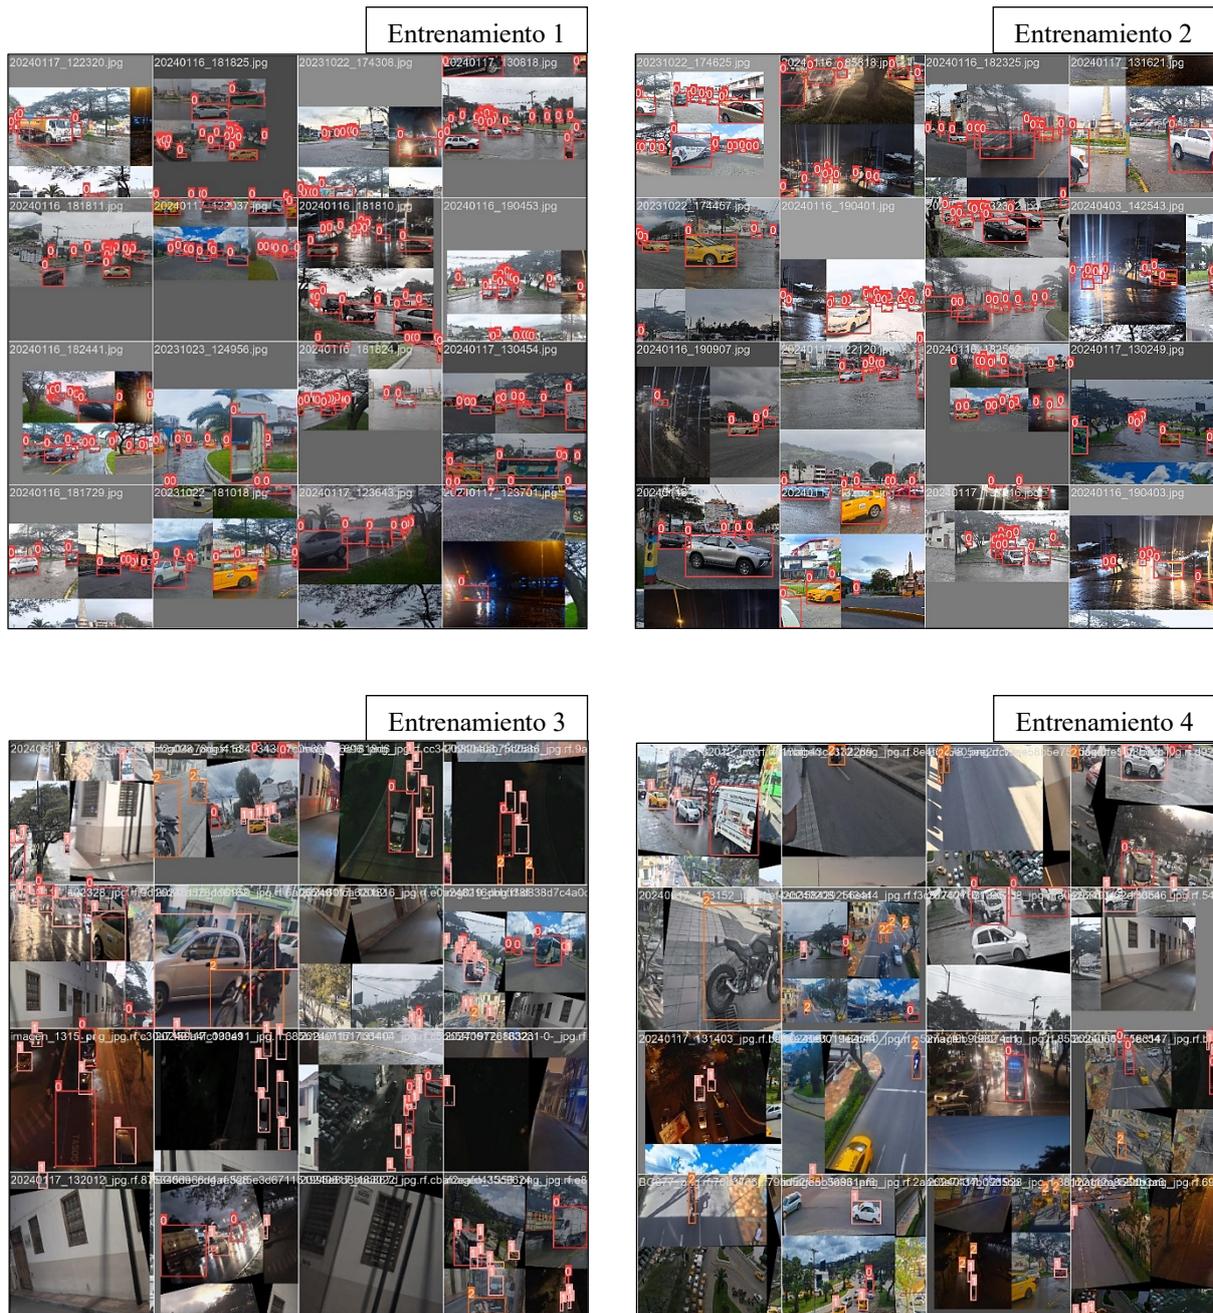


Las curvas de los entrenamientos 1 y 2 revelan que el modelo es candidato a ser mejorado puesto que la curva se mantiene constante y no desarrolla niveles altos de puntaje F1. En cambio, los entrenamientos 3 y 4 se destacan por tener un 88% en todas las clases que armonizan el equilibrio entre la precisión y recall de los modelos.

6.2.8 Batch del proceso de entrenamiento.

Figura 31

Batch generados en los entrenamientos.



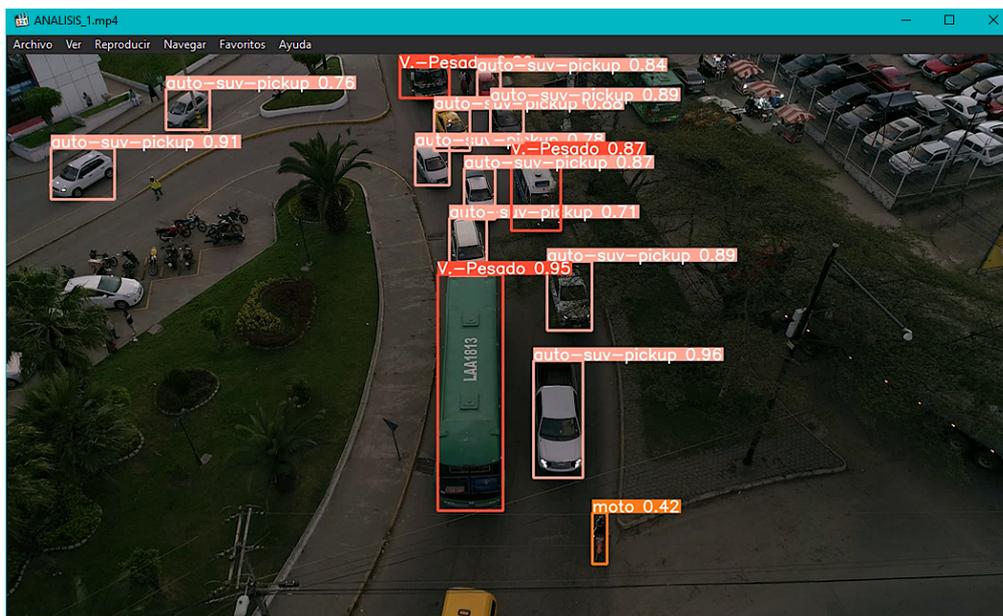
Los diferentes lotes de entrenamiento producidos muestran el trabajo que el sistema realiza al detectar y clasificar los diferentes vehículos etiquetados; independientemente del ángulo y nivel de iluminación, los modelos entrenados con Yolov5 fueron notablemente capaces de realizar la tarea de inferir correctamente al visualizar un vehículo y no confundirlo con otros objetos que puedan existir en el fotograma. También hay que destacar que los niveles bajos de background apenas infieren en posibles errores a la hora de realizar las detecciones.

6.3 Desempeño del modelo entrenado en nuevas imágenes.

Con los pesos y las métricas del entrenamiento obtenidos, se evaluó el rendimiento del mismo, para lo cual, se realizó una serie de pruebas de detección vehicular, aplicando los pesos obtenidos en videos e imágenes que no forman parte de la base de datos. Esto con el fin de verificar la eficacia que tiene el modelo para detectar vehículos y clasificarlos según las etiquetas asignadas.

Figura 32

Captura de Video Analizado con YOLOv5 en la Zona de Interés.



Nota. Imagen captada durante el proceso de detección donde se observa la inferencia en las diferentes clases de vehículos que es capaz de detectar. También se muestra el porcentaje decimal de la precisión en cada recuadro delimitador.

Durante la ejecución del análisis con YOLOv5, se presencié el desglose que hace el sistema en cada uno de los fotogramas que componen el video, captando y clasificando los vehículos existentes, además del porcentaje decimal de precisión obtenido en cada detección. El proceso requirió de un tiempo de inspección relativo en cuanto a la duración; puesto que los videos analizados oscilan entre 1, 3, 5 y 7 minutos, lo que llevó al computador demorar 18 minutos aproximadamente en cada video de entre 5 a 7 minutos. Cabe recalcar que este tiempo se reduce a medida que los recursos computacionales sean más potentes, sin embargo, el tiempo esperado es aceptable, dado que los videos fueron grabados con una alta resolución, lo que genera más trabajo al sistema dados los recursos disponibles. También se analizaron videos captados desde diferentes ángulos de la zona analizada, llegando al mismo resultado satisfactorio.

Una vez analizados los videos captados, se puede establecer que el modelo consiguió diferenciar las clases que circulan por la zona de análisis con bastante precisión; también se pudo observar confusiones puntuales generadas debido al ángulo de grabación. Por lo tanto, los pesos obtenidos en el entrenamiento 3 fueron los más aptos para su utilización en sistemas que requieran la detección de vehículos en tiempo real. Estos videos analizados se los puede visualizar en el link agregado en el Anexo 3.

6.4 Determinar el flujo vehicular.

6.4.1 *Conteo de vehículos*

Con el funcionamiento de los scripts comprobados, se inició un estudio de los siete videos captados con el dron. Como primer paso se ejecutó el conteo en cada uno de los videos obtenidos de manera manual y por otro lado se aplicó el sistema creado con YOLOv5 en PyCharm, ya que la cantidad de vehículos contabilizados es un dato crucial para aplicar en la fórmula y determinar el flujo vehicular.

Tabla 11

Vehículos Contabilizados

Video	Conteo Veh. Manual	Conteo Veh. con YOLOv5
ANALISIS_1.mp4	135	135

ANALISIS_2.mp4	60	59
ANALISIS_3.mp4	33	31
ANALISIS_4.mp4	116	115
ANALISIS_5.mp4	120	120
ANALISIS_6.mp4	132	115
ANALISIS_7.mp4	38	38

6.4.2 Tiempo de análisis aplicados

Dado que los videos sometidos al análisis tienen diferente tiempo de duración, este se estableció mediante el sistema creado en PyCharm, dando como resultado la siguiente información:

Tabla 12

Captación del Tiempo.

Video	Tiempo en segundos	Tiempo en minutos
ANALISIS_1.mp4	410	6,83
ANALISIS_2.mp4	192	3,2
ANALISIS_3.mp4	92	1,53
ANALISIS_4.mp4	330	5,5
ANALISIS_5.mp4	344	5,73
ANALISIS_6.mp4	410	6,83
ANALISIS_7.mp4	119	1,98

6.4.3 Flujo vehicular obtenido

Para asegurar que el sistema funciona correctamente se llevó a cabo una comparativa de los resultados obtenidos de manera manual con los resultados que el sistema fue capaz de obtener.

Tabla 13*Resultados del Flujo Vehicular de Manera Manual.*

Video	Vehículos contabilizados manualmente	Tiempo en segundos	Tiempo en minutos	Flujo Vehicular	
				veh/s	veh/min
ANALISIS_1.mp4	135	410	6,83	0,329	19,76
ANALISIS_2.mp4	60	192	3,2	0,312	18,75
ANALISIS_3.mp4	33	92	1,53	0,359	21,57
ANALISIS_4.mp4	116	330	5,5	0,351	21,09
ANALISIS_5.mp4	120	344	5,73	0,349	20,94
ANALISIS_6.mp4	132	410	6,83	0,321	19,33
ANALISIS_7.mp4	38	119	1,98	0,319	19,19

Tabla 14*Resultados del Flujo Vehicular Aplicando YOLOv5.*

Video	Vehículos contabilizados aplicando YOLOv5	Tiempo en segundos	Tiempo en minutos	Flujo Vehicular	
				veh/s	veh/min
ANALISIS_1.mp4	135	410	6,83	0,329	19,76
ANALISIS_2.mp4	59	192	3,2	0,307	18,44
ANALISIS_3.mp4	31	92	1,53	0,337	20,26
ANALISIS_4.mp4	115	330	5,5	0,348	20,91
ANALISIS_5.mp4	120	344	5,73	0,349	20,94
ANALISIS_6.mp4	115	410	6,83	0,280	16,84
ANALISIS_7.mp4	38	119	1,98	0,319	19,19

Se puede apreciar que los resultados obtenidos con YOLOv5 son bastante cercanos al conteo que se realizó manualmente. El hecho de que no sea perfecto se debe a una serie de factores que influyeron durante el conteo además de las condiciones climáticas. En primer lugar, las corrientes de aire afectaban a la estabilidad del dron y en varias ocasiones la grabación cambia ligeramente el ángulo, afectando así a las coordenadas de la ROI y a la línea contabilizadora; no obstante, se modificaron de tal modo que, si existiera un repentino cambio en el ángulo de grabación, este seguiría cumpliendo el objetivo de conteo. Esto puede ser solucionado fácilmente con una cámara completamente estática.

En segundo lugar, muchos motociclistas no transitaban correctamente por un carril, sino que circulan entre ellos, dificultando la captación de la moto y por ende su contabilización; a pesar de esta mala práctica por parte de ellos, el sistema consiguió captar la mayoría de motocicletas que atravesaron la zona de análisis. Por otro lado, también se observó que la iluminación de la zona en horario nocturno complica en cierto modo la captación precisa de los diferentes vehículos circundantes.

6.4.4 Efectividad del sistema de detección

Con el fin de saber el porcentaje de acierto del sistema creado, se aplicó la siguiente fórmula de la eficacia, (Romani Alejo, Romani Alejo, & Roque Barrios, 2023), que compara el método manual con la implementación de YOLOv5:

$$Eficacia = \frac{\text{Resultado alcanzado (RA)} \times 100}{\text{Resultado previsto (RP)}} \quad (\text{Ecuación 6})$$

Tabla 15

Cálculo de la Eficacia del Sistema con YOLOv5, en Segundos.

Vídeo	Flujo vehicular en segundos		Efectividad con YOLOv5 en %
	Manual (RP)	aplicando YOLOv5 (RA)	
ANALISIS_1.mp4	0,329	0,329	100 %
ANALISIS_2.mp4	0,312	0,307	98,40 %

ANALISIS_3.mp4	0,359	0,337	93,87 %
ANALISIS_4.mp4	0,351	0,348	99,14 %
ANALISIS_5.mp4	0,349	0,349	100%
ANALISIS_6.mp4	0,321	0,280	87,23 %
ANALISIS_7.mp4	0,319	0,319	100 %
PROMEDIO DE EFECTIVIDAD			96,95 %

Tabla 16

Cálculo de la Eficacia del Sistema con YOLOv5, en Minutos.

VÍDEO	Flujo vehicular en minutos		Efectividad con YOLOv5 en %
	manual	aplicando YOLOv5	
ANALISIS_1.mp4	19,76	19,76	100 %
ANALISIS_2.mp4	18,75	18,44	98,35 %
ANALISIS_3.mp4	21,57	20,26	93,92 %
ANALISIS_4.mp4	21,09	20,91	99,15 %
ANALISIS_5.mp4	20,94	20,94	100 %
ANALISIS_6.mp4	19,33	16,84	87,12 %
ANALISIS_7.mp4	19,19	19,19	100 %
PROMEDIO DE EFECTIVIDAD			96,93 %

Mediante este cálculo se establece que el sistema creado en PyCharm, junto con el modelo entrenado en Yolov5, es capaz de determinar con éxito el flujo vehicular de una zona crítica de la ciudad de Loja. Dado que los resultados obtenidos fueron satisfactorios, y con una alta precisión, tanto en aspecto de la aplicación de YOLOv5, como en el cálculo del flujo vehicular. Los resultados arrojados por el sistema pueden visualizarse en el Anexo 6. Es preciso mencionar que el sistema está diseñado con la flexibilidad necesaria para incorporar eventuales

mejoras en cuanto su efectividad, puesto que ningún modelo es perfecto y siempre existirá un margen para optimizar su funcionamiento.

Gracias a los análisis obtenidos se puede automatizar el análisis del tráfico para identificar patrones de congestión en tiempo real, dando así una alternativa importante para la prevención de accidentes; además brinda a las autoridades locales datos precisos sobre el comportamiento del tráfico para planificar una mejor infraestructura vial y estrategias de circulación como carriles reversibles, restricciones en horas pico, la promoción del transporte público, programación de semáforos o ajustes de rutas. Como último punto, la gestión ambiental con respecto al tráfico, ayuda a evaluar la calidad de aire y ruido generado, permitiendo elaborar políticas para reducir la contaminación.

7. Discusión

De acuerdo con los resultados obtenidos en el presente estudio se demostró que YOLOv5 es altamente confiable para determinar el flujo vehicular en una zona crítica de la ciudad de Loja. La eficacia demostrada del sistema, alcanza el 96,95%, evidenciando que los modelos de visión computarizados, pueden alcanzar y superar a los métodos tradicionales en términos de exactitud y eficiencia en el procesamiento de datos.

Al establecer una comparación con estudios relacionados, se menciona a (Ogoño Anguisaca & Orozco Calva), quienes analizaron el tránsito vehicular en algunas intersecciones del centro la ciudad de Loja para determinar el nivel de servicio que esta posee; estableciendo un flujo de vehículos por hora (entre 700 a 800 veh/h), menor al de la zona del Terminal Terrestre. Se aplicaron métodos de conteo tradicionales y técnicas de medición manual. Es aquí donde el procesamiento de datos por modelos de visión computarizados tendría un papel fundamental que cumplir para la captación de información relevante que ayude en investigaciones necesarias de la gestión de tránsito. Por ello el sistema desarrollado en este estudio, proveería de reportes sobre el flujo vehicular con una alta precisión y eficiencia.

También, (Illapuma Sutta) recurre a grabaciones filmicas para el posterior conteo de vehículos de manera visual, dentro de su proyecto establece un plan de obtención de datos típico y poco eficiente; de este modo, se reafirma una vez más que el sistemas de visión por computadora para la detección y conteo de vehículos desarrollado es más eficiente que la aplicación de técnicas tradicionales, ya que el tiempo de conteo se reduce significativamente y además está automatizado.

A pesar de las limitaciones que se originaron durante el desarrollo del proyecto, se obtuvieron importantes implicaciones prácticas. Los resultados obtenidos son una guía para desarrollar políticas de tráfico más seguras y efectivas para optimizar la infraestructura vial existente, como es el caso de (Caicedo M., 2023) quien aplicó Yolov5s para evaluar el riesgo de colisión trasera entre vehículos de la ciudad de Bogotá, obteniendo un modelo entrenado con 91,2% de mAP@50; sin duda un gran porcentaje de precisión que comparado con el desarrollado en el presente proyecto (91,3% de mAP@50) gozan de una excelente métrica de detección vehicular predispuesta para cualquier actividad relacionada con la gestión de tráfico.

8. Conclusiones

Es importante que el conjunto de datos establezca una similitud con la zona puesta a estudio, ya que elevará con gran éxito la precisión que el modelo pueda llegar a obtener en los entrenamientos. La variedad de vehículos también contribuye a la causa.

La configuración de los hiperparámetros para entrenar un modelo, debe ir acorde con el Hardware utilizado en el desarrollo del sistema, puesto que no todas las computadoras son capaces de soportar ciertas configuraciones.

Las métricas obtenidas son decisivas a la hora de determinar si un modelo puede superarse o en su opuesto, modificar el etiquetado y base de datos. En el caso del modelo #4 se observó claramente que existe un sobreentrenamiento, por ello terminó descartándose, a pesar de tener un buen rendimiento.

Los flujos vehiculares obtenidos dictaminan que en la zona puesta a estudio posee una gran afluencia de tráfico y variedad de vehículos, que, con el tiempo, aumentará y deberán aplicarse estrategias que mejoren la circulación vehicular y contaminación producida.

La implementación del sistema YOLOv5 logró obtener una efectividad del 96,95% en el cálculo del flujo vehicular, esto, junto con el sistema de conteo se vuelve una herramienta eficiente para la obtención de información relevante del tránsito ocasionado en la zona de análisis.

La comparación con estudios donde se aplican métodos tradicionales, demuestra que YOLOv5 brinda ventajas significativas en términos de precisión y velocidad, lo que la vuelve una herramienta altamente viable para la gestión del tráfico en zonas críticas.

Las limitaciones del sistema, se relacionan con la calidad de imágenes en condiciones de poca luz, la variabilidad de vehículos y la necesidad de un Hardware potente para el procesamiento en tiempo real.

El presente estudio aporta en el campo de la visión por computadora aplicada a la gestión del tráfico, evidenciando la eficacia y efectividad de Yolov5 para futuras implementaciones en entornos urbanos y automotrices, dado su gran potencial.

9. Recomendaciones

Es necesaria una investigación previa acerca del funcionamiento de YOLOv5 y su alcance, así como el uso de PyCharm y las plataformas usadas para el procesamiento de datos. De este modo, será más sencillo alcanzar los objetivos propuestos.

Para mejorar la precisión del sistema es necesaria la ampliación y selección exhaustiva de la base de datos, puesto que a mayor información el sistema aprenderá de mejor manera y habrá un aprendizaje más heterogéneo. Se sugiere descartar imágenes donde existan vehículos a largas distancias del punto de análisis.

Los resultados obtenidos en el estudio pueden ser implementados en sistemas de gestión de tráfico en tiempo real en la ciudad de Loja y en otras urbes con problemas similares. Se recomienda proponer a las autoridades locales la implementación y evolución de estos sistemas para solucionar los problemas causados por el tránsito.

Para desarrollar y conocer los diferentes elementos y variables del flujo de tránsito se debe modificar el funcionamiento del sistema desde el código principal para agregar scripts secundarios que realicen estos cálculos, por lo que se aconseja indagar en la lógica que modificaría los códigos del presente sistema.

Se sugiere realizar investigaciones futuras que aborden las limitaciones existentes en el presente estudio, como la implementación de un potente Hardware e instalación de estructura en la zona crítica, para colocar cámaras que visualicen de manera clara y sin obstáculos el tráfico producido. Además, explorar la integración de YOLOv5 con otras tecnologías emergentes como el Internet de las Cosas y la inteligencia artificial avanzada, para desarrollar sistemas de gestión vehicular aún más eficientes.

10. Bibliografía

- Alarcon, A. (2022). Detección de la señalización de tránsito vertical con redes neuronales convolucionales basadas en bloques residuales. *Difusión cultural y científica de la Universidad La Salle en Bolivia*, 24(24). Obtenido de http://www.scielo.org.bo/scielo.php?script=sci_arttext&pid=S2071-081X2022000200010&lng=es&tlng=es
- Amazon. (23 de Marzo de 2024). *Amazon.com*. Obtenido de Amazon.com: https://www.amazon.com/s?k=dji+and+phantom+4+pro&adgrpid=80389610094&hvadid=585359104746&hvdev=c&hvlocphy=1005375&hvnetw=g&hvqmt=b&hvrnd=10855600847686202423&hvtargid=kwd-858037514069&hydadcr=2775_13541856&tag=hydglogoo-20&ref=pd_sl_9ml3jr10r2_b
- Ashhad, T., Cabrera, F., & Roa, O. (2020). *Análisis de congestiónamiento vehicular para el mejoramiento de la vía principal en Guayaquil-Ecuador*. [Artículo de investigación, Universidad de Guayaquil] Depósito legal 1999907LA22, Guayaquil. doi:10.13140/RG.2.2.21905.04960
- Ayob, A. F., Khairuddin, K., Mastafah, Y. M., Salisa, A. R., & Kadir, K. (2021). Analysis of Pruned Neural Networks(MobileNetV2-YOLO v2)for Underwater Object Detection. *Analysis of Pruned Neural Networks(MobileNetV2-YOLO v2)for Underwater Object Detection*. University Malaysia Terengganu, Malaysia. doi:https://doi.org/10.1007/978-981-15-5281-6_787
- Berzal, F. (2018). *Redes Nueronales & Depp Learning*. Obtenido de <https://vdoc.pub/documents/redes-neuronales-deep-learning-4ou7rq5ahv80>
- Blanco, B., Dorantes, C., Gómez, D., & Morales, J. (2017). *Cálculo del flujo vehicular mediante segmentación*. [Tesis de grado, Instituto Politécnico Nacional], Repositorio digital Dspace, México D.F. Obtenido de <http://tesis.ipn.mx/handle/123456789/21133>
- Caicedo M., Y. (2023). Adaptación de YOLO Versión 5 Para Detección de Vehículos en Espacio 3D sobre Imágenes Monoculares. *Adaptación de YOLO Versión 5 Para Detección de Vehículos en Espacio 3D sobre Imágenes Monoculares*. Pontificia Universidad Javeriana., Bogotá. Obtenido de https://repository.javeriana.edu.co/bitstream/handle/10554/65639/attachment_0_TG2_Final_V6_Final_Aprobado_DirectoresTG.pdf?sequence=1&isAllowed=y

- Cal, R., & Cárdenas, J. (2018). *Ingeniería de Tránsito Fundamentos y Aplicaciones*. Alfaomega.
- Carpio, F., Avilés, J., & Morillo, D. (2018). *Determinación de capacidad de carreteras en Cuenca (Ecuador)*. Universidad de Cuenca, Cuenca. doi:10.18537/mskn.09.01.11
- Carpio Quizhpi, J. D., & Mejía Carpio, I. A. (2023). *Estudio de tráfico y soluciones al congestionamiento vehicular (Intersección Av. 24 de Mayo Y Av. Gapal)*. Universidad Politécnica Salesiana Sede Cuenca, Cuenca. Obtenido de <https://dspace.ups.edu.ec/bitstream/123456789/25421/4/UPS-CT010666.pdf>
- Cerón, Ó. (2007). *Análisis del tráfico vehicular en una zona crítica de la ciudad de Quito*. [Tesis del título de magister, Escuela Politécnica Nacional], Repositorio digital EPN, Quito. Obtenido de <https://bibdigital.epn.edu.ec/bitstream/15000/19507/1/CD-1130.pdf>
- Chen, Z., Cao, L., & Wang, Q. (2 de mayo de 2022). YOLOv5 Based Vehicle Detection Method for High-Resolution UAV Images. *Hindawi, MMXXII*(1828848), 2-5. doi:doi.org/10.1155/2022/1828848
- Díaz Silva, S. E., & Horna Martínez, P. (2022). *Flujo vehicular y peatonal en la intersección de las calles Francisco Orellana y Luna Pizarro empleando el software PTV Vissim en la ciudad de Jaén-Cajamarca-2022*. Universidad Nacional de Jaén, Jaén. Obtenido de http://repositorio.unj.edu.pe/bitstream/UNJ/516/1/IFT_D%C3%ADaz%20Silva_Horna%20Martinez_CIVIL.pdf
- Espinel, Á., & Jaramillo, J. (2022). *ANÁLISIS DE TRÁFICO Y ALTERNATIVAS DE SOLUCIÓN PARA EL CONGESTIONAMIENTO VEHICULAR EN LA INTERSECCIÓN DE LA AVENIDA MARISCAL SUCRE Y SAN FRANCISCO DE RUMIHURCO EN LA CIUDAD DE QUITO A TRAVÉS DEL SOFTWARE PTV VISSIM*. [Tesis de grado, Pontificia Universidad Católica del Ecuador], Repositorio PUCE, Quito. Obtenido de <http://repositorio.puce.edu.ec/bitstream/handle/22000/20199/TESIS%20DE%20GRADO%20JOSE%20JARAMILLO%20-%20ANGEL%20ESPINEL%20-%202022.pdf?sequence=1&isAllowed=y>
- Febres Loaiza, D. A. (2022). *repositorio.uide.edu.ec*. Obtenido de [repositorio.uide.edu.ec: https://repositorio.uide.edu.ec/handle/37000/5079](https://repositorio.uide.edu.ec/handle/37000/5079)
- Flores, F. (2020). *Aplicación de métodos de big data para la detección de líneas bypass en operadoras telefónicas*. [Tesis de grado, Universidad de las Américas], Repositorio digital de la UDLA. Obtenido de <https://dspace.udla.edu.ec/bitstream/33000/12731/1/UDLA-EC-TIRT-2020-31.pdf>

- Gómez, J., & Delgado, D. (2022). *El congestionamiento vehicular, análisis y propuesta de solución: intersección semaforizada entre Avenidas América y Reales Tamarindos, Portoviejo, Ecuador*. Universidad Técnica de Ambato, Ambato. doi:<https://doi.org/10.31243/id.v16.2022.1732>
- González Cartagena, J. V. (2023). *Gestión de tránsito como metodología para mitigar la congestión*. Escuela superior Politécnica de Chimborazo, Riobamba. Obtenido de <http://dspace.espoch.edu.ec/bitstream/123456789/19257/1/20T01695.pdf>
- Illapuma Sutta, J. (s.f.). Análisis del flujo vehicular en intersecciones no semaforizadas del distrito de San Sebastián. *Análisis del flujo vehicular en intersecciones no semaforizadas del distrito de San Sebastián*. Universidad Andina del Cusco, Cusco. Obtenido de https://repositorio.uandina.edu.pe/bitstream/handle/20.500.12557/5004/Julio_Tesis_bachiller_2022.pdf?sequence=1&isAllowed=y
- INEC. (5 de Octubre de 2023). *ecuadorencifras.gob.ec*. Obtenido de [ecuadorencifras.gob.ec](https://www.ecuadorencifras.gob.ec): <https://www.ecuadorencifras.gob.ec/35-079-personas-mas-viven-en-la-provincia-de-loja/>
- INEC. (2 de Mayo de 2024). *ecuadorcifras.gob.ec*. Obtenido de [ecuadorcifras.gob.ec](https://www.ecuadorencifras.gob.ec): https://www.ecuadorencifras.gob.ec/documentos/web-inec/Estadisticas_Economicas/Estadistica%20de%20Transporte/ESTRA_2022/2022_TABULADOS%20ESTRA.xlsx
- INEN. (2011). *obraspublicas.gob.ec*. Obtenido de [obraspublicas.gob.ec](https://www.obraspublicas.gob.ec): https://www.obraspublicas.gob.ec/wp-content/uploads/downloads/2015/03/LOTAIP2015_reglamento_tecnico_se+alizaci+n_horizantal.pdf
- JetBrains. (29 de Mayo de 2024). *jetbrains.com*. Obtenido de [jetbrains.com](https://www.jetbrains.com): <https://www.jetbrains.com/es-es/pycharm/download/?section=windows>
- Li, S., Yang, X., Lin, X., Zhang, Y., & Wu, J. (16 de Junio de 2023). Real Time Vehicle Detection from UAV Aerial Images Based on Improved YOLOv5. *Sensors*, *XXIII*(12), 2-5. doi:doi.org/10.3390/s23125634
- Maps, G. (8 de Mayo de 2024). Intersección de Av. Isidro Ayora y Av. 8 de Diciembre. Loja. Obtenido de <https://maps.app.goo.gl/Te27nFgWAqPdqeCT8>
- Martínez, R. (2022). *Sistema Inteligente de Análisis de Imágenes de Detección de Comportamiento*. [Tesis de grado, Universidad Politécnica de Madrid], Repositorio digital de la UPM, Madrid. Obtenido de https://oa.upm.es/71604/1/TFG_ROCIO_MARTINEZ_COMIN.pdf

- Montenegro, B., & Flores, M. (2022). Detección de peatones en el día y en la noche usando YOLO-v5. *Revista de Ciencia y Tecnología*, 27, 85-95. doi:<https://doi.org/10.17163/ings.n27.2022.08>
- Moreira Ramos, D. (2021). *Aplicación de un modelo de reconocimiento de objetos utilizando Yolo (You Only Look Once)*. Universidad Estatal Península de Santa Elena, La Libertad. Obtenido de <https://repositorio.upse.edu.ec/bitstream/46000/5755/1/UPSE-TTI-2021-0008.pdf>
- Mozo, J. (2012). *Análisis de nivel de servicio y capacidad de segmentos básicos de autopistas, segmentos trenzados y rampas de acuerdo al manual de capacidad de carreteras HCM2000 aplicando MATHCAD*. México DF. Obtenido de <http://www.ptolomeo.unam.mx:8080/xmlui/bitstream/handle/132.248.52.100/417/A4.pdf?sequence=4&isAllowed=y>
- Municipio de Loja. (2023). *loja.gob.ec*. Obtenido de [loja.gob.ec: https://www.loja.gob.ec/files/documentos/2023-12/ord._0058-2023._reforma_pdot_ok.pdf](https://www.loja.gob.ec/files/documentos/2023-12/ord._0058-2023._reforma_pdot_ok.pdf)
- Ogoño Anguisaca, J. R., & Orozco Calva, L. F. (s.f.). *Análisis del tránsito vehicular en las intersecciones viales en el centro histórico de la ciudad de Loja, determinando el nivel de servicio*. Universidad Politécnica Salesiana Sede Cuenca, Cuenca. Obtenido de <https://dspace.ups.edu.ec/bitstream/123456789/19381/1/UPS-CT008854.pdf>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2015). You Only Look Once: Unified, Real-Time Object Detection. *Arxiv*, 5. doi:doi.org/10.48550/arXiv.1506.02640
- Romani Alejo, G. E., Romani Alejo, N. S., & Roque Barrios, N. E. (1 de mayo de 2023). *repositorio.cidecuador.org*. Obtenido de https://repositorio.cidecuador.org/bitstream/123456789/2392/1/2Libro%20La%20Eficiencia.VF_24_5_2023pdf.pdf
- Ruiz, Á., Sánchez, K., & Arteaga, L. (12 de Noviembre de 2019). MODELOS DE ORDENACIÓN DEL TRÁFICO DE LA. *Revista CIENCIA*, 21(2), 31-32. doi:<https://doi.org/10.24133/ciencia.v21i2.1515>
- Sarango, E. (8 de Junio de 2024). Obtenido de https://github.com/EdwinST8/Count_Loja2024
- Shao, L., Wu, H., Li, C., & Li, J. (2023). A vehicle recognition model based on improved YOLOv5. *Electronics*. doi:doi.org/10.3390/electronics12061323
- Sincerefirst. (10 de Febrero de 2024). *cameramodule.com*. Obtenido de [cameramodule.com: http://es.cameramodule.com/fpc-camera-module/mipi-camera-module/50mp-sony-imx766-camera-module.html](http://es.cameramodule.com/fpc-camera-module/mipi-camera-module/50mp-sony-imx766-camera-module.html)

- Snegireva, D., & Kataev, G. (17 de Septiembre de 2021). Vehicle Classification Application on Video Using Yolov5 Architecture. *IEEE Xplore*. doi:10.1109/RusAutoCon52004.2021.9537439.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., . . . Rabinovich, A. (2014). Going Deeper with Convolutions. *Arxiv*. doi:doi.org/10.48550/arXiv.1409.4842
- Ubuy. (11 de Febrero de 2024). *ubuy.es*. Obtenido de ubuy.es: <https://www.ubuy.ec/es/product/3V6PCZOFQ-aideepen-esp32-cam-wifi-bluetooth-board-esp32-cam-mb-micro-usb-to-serial-port-ch340g-with-ov2640-2mp-camera-module-dual-mode-for-arduino>
- Ultralytics. (21 de Marzo de 2024). *docs.ultralytics.com*. Obtenido de docs.ultralytics.com: https://docs.ultralytics.com/es/yolov5/tutorials/train_custom_data/#3-select-a-model
- Ultralytics. (4 de Mayo de 2024). *Github*. Obtenido de Github: <https://github.com/ultralytics/yolov5>
- Valls, T. (2023). *EVALUACIÓN DE RENDIMIENTO DE YOLOV5 Y ALGORITMOS DE*. [Tesis de grado, Universidad de Chile], repositorio digital de Uchile, Santiago. Obtenido de <https://repositorio.uchile.cl/bitstream/handle/2250/191847/Evaluacion-de-rendimiento-de-YOLOv5-y-algoritmos-de-seguimiento-en-una-Jetson-Nano-2GB.pdf?sequence=1>

11. Anexos

Anexo 1. *Base de Datos en Roboflow.*

Puesto que la plataforma Roboflow establece que las bases de datos trabajadas en su entorno deben ser públicas, el conjunto de datos recopilado en el proyecto se lo puede obtener mediante el siguiente link o mediante el id:

- https://universe.roboflow.com/bd20244-cy0u2/bd_2024_4-vxbuf/dataset/1
- bd_2024_4-vxbuf

Anexo 2. *Códigos para el Funcionamiento de YOLOv5.*

El código debe ser instalado en el Cmd de la computadora siguiendo la guía de instalación proporcionada en el repositorio oficial de Yolov5 en Github, además existe la guía para la puesta en marcha de entrenamientos, detecciones y validaciones:

- <https://github.com/ultralytics/yolov5>

Anexo 3. *Detecciones en los videos analizados con YOLOv5.*

Se recopiló en una lista de reproducción las detecciones realizadas en los vídeos captados con dron aplicando los pesos del tercer entrenamiento a partir de la base de datos final. El siguiente link pertenece a la plataforma YouTube:

- <https://youtube.com/playlist?list=PLC0r5X5v8up3h-2eL7mgic-DT12T8blys&si=-aGIA5CIyt8gZzTM>

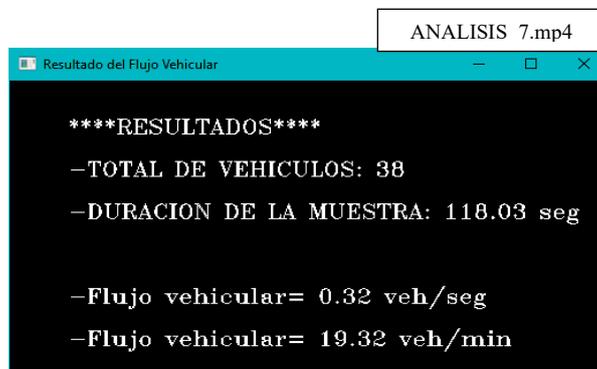
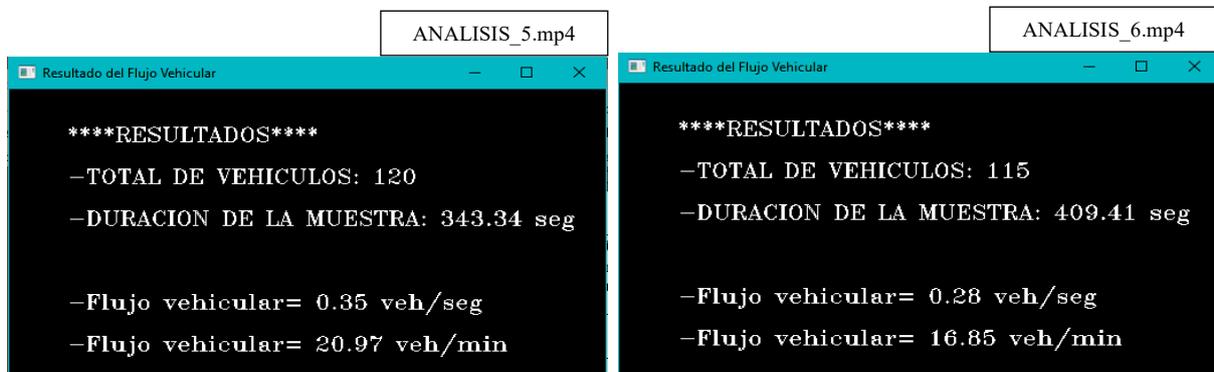
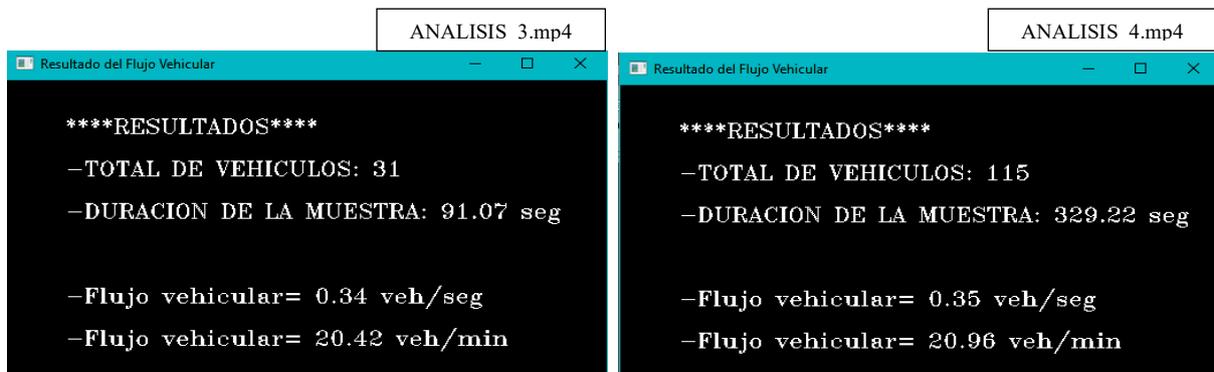
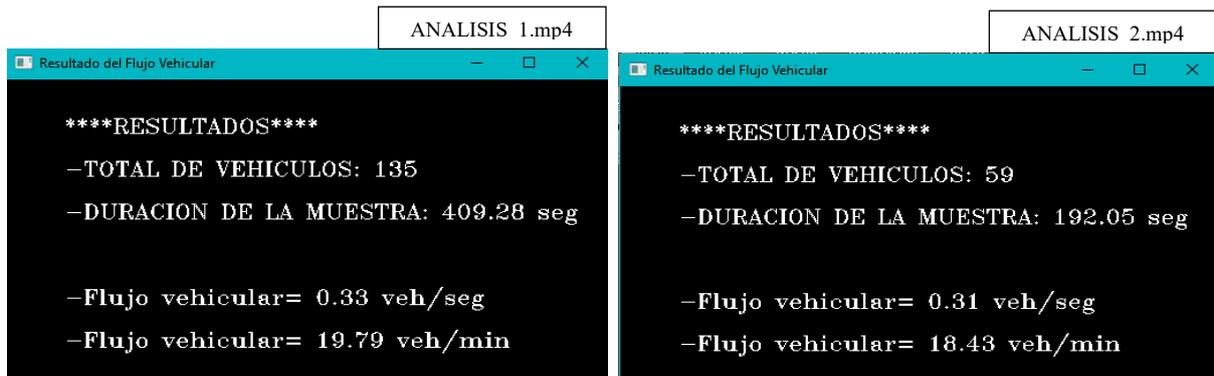
Anexo 4. *Repositorio del Proyecto IR_5.*

Se creo un repositorio personal, de carácter público, en la plataforma Github que contiene todos los scripts y archivos utilizados en el proyecto. Además, existe una guía para poner en práctica el sistema.

- https://github.com/EdwinST8/Count_Loja2024-IR_5.git

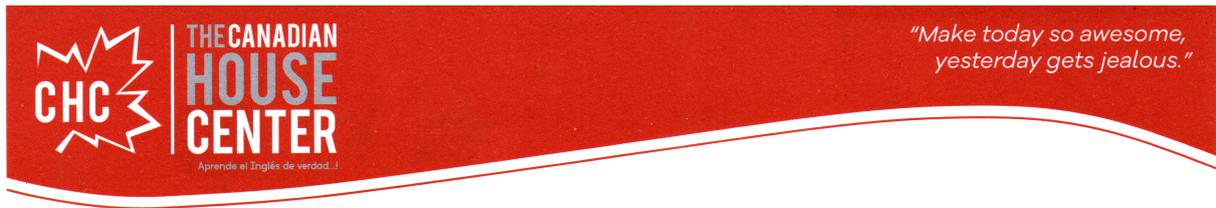
Anexo 5. *Resultados del Flujo Vehicular desde PyCharm.*

Al finalizar el proceso de conteo en PyCharm aparece un frame con el cálculo del flujo vehicular del video analizado, además de los datos empleados en el cálculo.



Todos los resultados obtenidos se los plasmó con aproximaciones de dos y tres decimales en las tablas de comparación del flujo vehicular. Estos resultados son el producto del análisis de cada vídeo captado con el dron simulando una cámara de tráfico.

Anexo 6. Certificado de traducción del resumen.



Loja, 30 de septiembre del 2024

CERTIFICADO DE TRADUCCIÓN

A quien corresponda,

Yo, José Geovanny Jiménez Balcázar, traductor oficial del The Canadian House Center, instituto privado especializado en la enseñanza del inglés como lengua extranjera y centro de traducción autorizado y acreditado por el Consejo Nacional de la Judicatura del Ecuador bajo la licencia profesional número 12282677, certifico que el resumen de tesis titulada: **Determinación del flujo vehicular en una zona crítica de la ciudad de Loja aplicando YOLOv5**, realizada por *Edwin Fernando Sarango Tacuri*, portador de la cédula de identidad ecuatoriana 1900541820, de la carrera de Ingeniería en Mecánica Automotriz de la Universidad Nacional de Loja, ha sido traducido de buena fe del español al inglés en la institución antes mencionada, y es una traducción fiel y exacta del documento original según mi leal saber y entender.

El portador puede hacer uso de este certificado y del documento traducido para cualquier fin legal que consideren oportuno.



Lic. José Geovanny Jiménez Balcázar
TRADUCTOR OFICIAL
THE CANADIAN HOUSE CENTER
Email: chcloja@gmail.com
Tel: +593 (0)7 258 5435



CHC MATRÍZ: Venezuela 19 - 77 e/ José María Peña y Av. Pío Jaramillo Alvarado
CHC CENTRO: Miguel Riofrío 14 - 35 entre Bolívar y Sucre
2565257 (Chc Centro) • 2585435 (Chc Matriz)

www.thecanadianhousecenter.com

