

**UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL
DE HUAMANGA**

**FACULTAD DE INGENIERÍA DE MINAS, GEOLOGÍA Y
CIVIL**

ESCUELA PROFESIONAL DE INGENIERÍA CIVIL



TESIS:

**Propuesta de modelo de tráfico vehicular, mediante redes
neuronales artificiales, para reducir la congestión vehicular
en el Jirón Carlos F. Vivanco, Ayacucho, 2024**

Para optar el título profesional de:

INGENIERO CIVIL

PRESENTADO POR:

Bach. Diego Omar TENORIO HUARANCCA

ASESOR:

Dr. Ing. Hemerson LIZARBE ALARCÓN

AYACUCHO - PERÚ

2025

RESUMEN

La presente investigación desarrolló un modelo de tráfico vehicular basado en redes neuronales artificiales para reducir la congestión en el Jirón Carlos F. Vivanco, Ayacucho, una zona crítica debido a su diseño colonial incompatible con el tránsito moderno. La investigación se estructuró en tres objetivos específicos: El diseño de una arquitectura robusta para detección vehicular en condiciones heterogéneas que incluyen tráfico variable, diversas condiciones ambientales (precipitaciones, iluminación solar variable, sombras proyectadas) y entornos nocturnos con visibilidad limitada; la optimización del entrenamiento del modelo para lograr alta precisión clasificatoria; y el desarrollo de un algoritmo de optimización dinámica de ciclos semafóricos. Metodológicamente, se implementó la arquitectura YOLO (You Only Look Once), entrenada durante 126 épocas mediante la técnica de Early Stopping, y se utilizaron herramientas como LabelMe para el etiquetado del conjunto de datos. El modelo alcanzó métricas sobresalientes: Precisión del 88.7%, valores de recall de 0.832 (validación) y 0.834 (evaluación), con tiempos de procesamiento ultrarrápidos. El sistema optimizó los ciclos semafóricos según la densidad vehicular, asignando tiempos diferenciados para densidades bajas, medias y altas. Los resultados demostraron la eficacia del modelo integrado para mejorar la movilidad urbana, reducir el impacto ambiental y optimizar infraestructura vial existente, estableciendo un precedente metodológico para implementar sistemas de transporte inteligente en contextos locales específicos.

Palabras clave : Redes neuronales artificiales, congestión vehicular, semáforos inteligentes, YOLO (You Only Look Once).

SUMMARY

This research developed a vehicular traffic model based on artificial neural networks to reduce congestion in Jirón Carlos F. Vivanco, Ayacucho, a critical area due to its colonial design incompatible with modern transit. The research was structured around three specific objectives: Designing a robust architecture for vehicle detection under heterogeneous conditions including variable traffic, diverse environmental conditions (precipitation, variable solar illumination, projected shadows) and nighttime environments with limited visibility; optimizing the model training to achieve high classification accuracy; and developing an algorithm for dynamic optimization of traffic light cycles. Methodologically, the YOLO (You Only Look Once) architecture was implemented, trained for 126 epochs using the Early Stopping technique, and tools such as Labelme were used for dataset labeling. The model achieved outstanding metrics: 88.7 % precision, recall values of 0.832 (validation) and 0.834 (evaluation), with ultra-fast processing times. The system optimized traffic light cycles according to vehicular density, assigning differentiated times for low, medium, and high densities. The results demonstrated the effectiveness of the integrated model for improving urban mobility, reducing environmental impact, and optimizing existing road infrastructure, establishing a methodological precedent for implementing intelligent transportation systems in specific local contexts.

Keywords: Artificial neural networks, vehicular congestion, intelligent traffic lights, YOLO (You Only Look Once).

INTRODUCCIÓN

La congestión vehicular constituye una problemática primordial que afecta a numerosas urbes a nivel global. Su abordaje trasciende la aplicación de soluciones universales, dada su complejidad intrínseca y su manifestación singular en cada contexto urbano. Esta particularidad se moldea por una variedad de factores distintivos, que incluyen la configuración de su red vial, la organización de su sistema de transporte público, los patrones característicos del flujo vehicular, su infraestructura de señalización vial, entre otros elementos determinantes.

En la ciudad de Ayacucho, la congestión vehicular emerge como uno de los principales desafíos que confrontan las autoridades públicas. Esta situación se agudiza debido a la naturaleza histórica de su centro, una ciudad colonial cuyo trazado original no fue concebido para el tránsito de vehículos motorizados, sino primordialmente para el desplazamiento de carruajes y personas. Adicionalmente, Ayacucho presenta una estructura monocéntrica, donde la mayoría de las actividades comerciales, educativas y laborales convergen hacia el centro de la ciudad. Esta centralización provoca que las estrechas calles del centro histórico dificulten una integración óptima del flujo vehicular con las principales vías arteriales y secundarias a las que sus calles confluyen. El Jirón Carlos F. Vivanco se distingue como un punto particularmente conflictivo, cuyas vías angostas resultan insuficientes para absorber la demanda vehicular durante las horas de mayor afluencia. Esta limitación obstaculiza la implementación de un sistema de regulación de tráfico eficiente, lo cual se manifiesta en un tránsito congestionado y caracterizado por una circulación lenta. Como factor agravante, el control del tráfico vehicular en Ayacucho se realiza mediante semáforos de tiempos fijos, que operan de manera independiente y aislada, con ciclos preestablecidos que no responden a la demanda vehicular real. Estos tiempos fijos son susceptibles a desprogramación rápida, generando patrones de “olas rojas” que, lejos de facilitar la circulación, obstaculizan significativamente el flujo vehicular.

Ante esta problemática que afecta a la población ayacuchana, la cual diariamente experimenta una considerable pérdida de tiempo productivo al quedar atrapada en el tráfico, surge la motivación por hallar una solución efectiva. Esta pérdida de tiempo no solo implica una disminución de la productividad general de la sociedad, ocasionada por la pérdida de valiosas horas laborales, sino que también se traduce en pérdidas económicas tangibles. Adicionalmente, la congestión vehicular ocasiona un incremento significativo del estrés tanto para los ciudadanos como para los conductores que se desplazan por la ciudad. A estos efectos se suma el aumento del consumo de combustible, directamente proporcional al incremento de las detenciones y arranques constantes de los vehículos. Finalmente, y de manera crucial, la congestión vehicular contribuye a la degradación de la calidad ambiental y al aumento de la contaminación auditiva, generando problemas de salud que afectan a toda la población ayacuchana. Es precisamente esta compleja situación la que impulsan la presente propuesta y motivan la búsqueda de una solución.

Con el propósito de abordar la problemática de la congestión vehicular, se plantea el desarrollo de un modelo de tráfico vehicular fundamentado en redes neuronales artificiales. Se concibe esta herramienta como un medio eficaz para mitigar la congestión tanto en el Jirón Carlos F. Vivanco, punto clave para aliviar el flujo de las vías adyacentes, como en la totalidad de la ciudad de Ayacucho. Para alcanzar este objetivo general, se establecen los siguientes objetivos específicos, intrínsecamente ligados al problema de investigación:

En primer lugar, se propone el diseño de una arquitectura robusta para la detección, clasificación y conteo eficiente de vehículos en condiciones heterogéneas de tráfico variable. Esta arquitectura deberá demostrar su eficacia ante las fluctuaciones de variabilidad del flujo vehicular. Asimismo, se requiere que opere de manera óptima en diversas condiciones ambientales, tales como precipitaciones (fenómeno representativo en Ayacucho entre diciembre y marzo), periodos de sol, nubosidad y entornos nocturnos, características esenciales para un modelo de tráfico vehicular integral.

En segundo lugar, una vez diseñada la arquitectura, se procederá al entrenamiento del modelo con el fin de lograr una detección y clasificación precisa de los vehículos que transitan por la ciudad. La exactitud en estas tareas es crucial, ya que errores en la clasificación, detección o conteo conducirían a resultados inadecuados para la optimización del tráfico. En este sentido, se optimizará el proceso de entrenamiento, implementando estrategias para evitar el sobreajuste y garantizar la generalización del modelo.

En tercer y último lugar, se abordará la creación de un algoritmo específico para la optimización dinámica de los ciclos semafóricos en función de la densidad vehicular. Este algoritmo tiene como objetivo superar las limitaciones inherentes a los semáforos de tiempos fijos, responsables de los problemas de congestión actuales. De esta manera, se busca proporcionar una solución ágil y viable al problema de la congestión vehicular tanto en el Jirón Carlos F. Vivanco como en el conjunto de la ciudad de Ayacucho.

El trabajo de investigación está organizado de la siguiente manera:

1. PLANTEAMIENTO DEL PROBLEMA

- En este apartado se formula el problema de investigación, describiendo su alcance a nivel mundial, nacional y regional. Además, se detallan los actores afectados, las causas y efectos potenciales, las condiciones en las que se manifiesta y el impacto socioeconómico en la población. Finalmente, se establece la delimitación espacial y temporal de la investigación, así como la temática y la unidad de análisis.

2. MARCO TEÓRICO

- Este apartado presenta los antecedentes internacionales y nacionales relevantes para comprender la evolución de la investigación. Asimismo, se exponen las bases teóricas de la congestión vehicular y los marcos conceptuales de los modelos de tráfico, fundamentando las teorías que sustentan el diseño del algoritmo y los sistemas inteligentes de transporte.

3. MARCO METODOLÓGICO

- En este apartado se detalla la metodología de la investigación, abarcando siete criterios clave con su respectiva justificación. Se define la población y la muestra estudiada, se formula la hipótesis central y se operacionalizan las variables, especificando sus dimensiones e indicadores. Además, se describen las técnicas e instrumentos de recolección de datos, detallando las características de cada herramienta utilizada. Finalmente, se explica exhaustivamente el desarrollo del trabajo de tesis, incluyendo el proceso de recopilación de datos, la cantidad y el etiquetado del conjunto de entrenamiento (con Labelme para cada clase vehicular), la conversión a formato YOLO, el proceso de entrenamiento (indicando el número de épocas), y, fundamentalmente, el diseño del algoritmo para la detección, clasificación y conteo de vehículos, así como para la predicción de ciclos semafóricos basada en la densidad UCP.

4. RESULTADOS

- En este apartado se presentan los resultados del modelo de tráfico vehicular, incluyendo capturas de pantalla, cuadros comparativos y métricas de entrenamiento. Se explican detalladamente cada uno de los gráficos generados por el modelo, contrastándolos con cada una de las tres hipótesis específicas de la investigación

5. CONCLUSIONES

- En este apartado se presentan las conclusiones de la investigación en relación con los objetivos y la hipótesis planteada. Además, se incluyen las recomendaciones derivadas del estudio y las sugerencias para futuras investigaciones.

6. ANEXOS

- Este apartado incluye el panel fotográfico de la instalación de las cámaras de investigación, las matrices de consistencia y operacionalización, los formatos utilizados para el conteo de los ciclos semafóricos, así como la documentación y los permisos otorgados por la municipalidad.

A mi madre Esther Huarancca, quien ha sido un pilar invaluable para mi formación personal y profesional, quien supo brindarme siempre su mano amiga en estos años de superación; a la familia Huarancca Aguilar, quienes me brindan su apoyo incommensurable para hacer frente a las dificultades en mis años de estudio. Ellos mi principal motivación e inspiración, este logro es también el suyo.

AGRADECIMIENTOS

A los diferentes ingenieros, de la escuela de formación profesional de Ingeniería Civil de la Universidad Nacional de San Cristóbal de Huamanga, por su orientación y las clases brindadas con las ganas de transmitir sus conocimientos.

Mi especial reconocimiento al Dr. Ing. Hemerson Lizarbe Alarcón, asesor de esta tesis, cuya sabiduría, dedicación y orientación constante fueron pilares fundamentales para la culminación exitosa de esta investigación.

A los distinguidos evaluadores, M.Sc.Ing. Rocky Giban Ayala Bizarro y M.Sc.Ing. Moises Nico Barbaran Oriundo, por su minuciosa revisión, valiosas sugerencias y compromiso con la excelencia académica, cualidades que elevaron significativamente la calidad de este trabajo.

Mi agradecimiento a la Sub Gerencia de Tránsito y Seguridad Vial, así como a la Sub Gerencia de Serenazgo de la Municipalidad Provincial de Huamanga, por su invaluable colaboración al proporcionar datos cruciales y permitir el acceso a sus instalaciones, facilitando enormemente el desarrollo de esta investigación.

A los colegas y amistades forjadas durante este proceso investigativo, quienes con sus conocimientos, perspectivas y apoyo incondicional contribuyeron a enriquecer y elevar la calidad del modelamiento de esta tesis.

Finalmente, extendiendo mi gratitud a todos aquellos que me acompañaron en este arduo pero gratificante camino académico. Su respaldo, palabras de aliento y compañerismo fueron el motor que impulsó la perseverancia necesaria para alcanzar esta meta profesional.

ÍNDICE GENERAL

ÍNDICE GENERAL	IX
1 PLANTEAMIENTO DEL PROBLEMA	4
1.1 Descripción del problema	4
1.2 Delimitación del problema	6
1.2.1 Espacial (geográfica)	6
1.2.2 Temporal	6
1.2.3 Temática y unidad de análisis	6
1.3 Formulación del problema	7
1.3.1 Problema general	7
1.3.2 Problemas específicos	7
1.4 Justificación e importancia	7
1.4.1 Conveniencia	7
1.4.2 Relevancia social	7
1.4.3 Aplicaciones prácticas	8
1.4.4 Unidad metodológica	8
1.4.5 Valor teórico	8
1.5 Limitaciones de la investigación	8
1.6 Objetivos de la investigación	9
1.6.1 Objetivo general	9
1.6.2 Objetivos específicos	9
2 MARCO TEÓRICO	10
2.1 Antecedentes	10
2.1.1 Investigaciones internacionales.	10
2.1.2 Investigaciones nacionales	12
2.2 Bases teóricas	14
2.2.1 Congestión vehicular	14
2.3 Marco conceptual	20
2.3.1 Modelo de tráfico vehicular	20
2.3.2 Sistemas inteligentes de transporte (ITS)	40
3 MARCO METODOLÓGICO	49
3.1 Método	49
3.2 Orientación	49
3.3 Enfoque.	49
3.4 Instrumento de recolección de datos	49
3.5 Tipo o alcance de la investigación	50
3.6 Nivel de investigación	50

3.7	Diseño de investigación	50
3.7.1	Propósito de la investigación.	50
3.7.2	Número de mediciones	50
3.7.3	Cronología de las observaciones	51
3.8	Estudio del diseño de investigación	51
3.9	Población y muestra.	51
3.9.1	Población	51
3.9.2	Muestra	51
3.10	Hipótesis	52
3.10.1	Hipótesis general	52
3.10.2	Hipótesis específicas	52
3.11	Operacionalización de variables	52
3.11.1	Variables	52
3.11.2	Dimensiones	52
3.11.3	Indicadores	53
3.12	Técnicas e instrumentos.	55
3.12.1	Técnicas de recolección	55
3.12.2	Instrumentos utilizados	56
3.12.3	Herramientas de software utilizadas.	56
3.13	Desarrollo del trabajo de tesis.	57
3.13.1	Recopilación de datos	57
3.13.2	Conjunto de datos de entrenamiento	63
3.13.3	Etiquetado en LabelMe	64
3.13.4	Preprocesamiento-conversión de J.SON a archivos Yolo	70
3.13.5	Entrenamiento para la clasificación y detección en Google Colab	72
3.13.6	Análisis de la intersección semafórica del Jr. Carlos F. Vivanco y Jr. Sol	90
3.13.7	Detección, clasificación y conteo de vehículos	92
3.13.8	Predicción de ciclos semafóricos basado en demanda vehicular y densidad UCP	96
4	RESULTADOS	100
4.1	Contrastación de hipótesis	100
4.1.1	Contrastación de hipótesis específica 1.	100
4.1.2	Contrastación de hipótesis específica 2.	118
4.1.3	Contrastación de hipótesis específica 3.	126
5	CONCLUSIONES	173
5.1	Conclusiones.	173
5.2	Recomendaciones	176
5.3	Trabajos futuros	176
	REFERENCIAS BIBLIOGRÁFICAS	178

6 ANEXOS	184
6.1 Panel fotográfico-instalación de cámaras de investigación	184
6.2 Matriz de consistencia y operacionalización - formatos de campo y documentación.	187

LISTA DE FIGURAS

1	Vista satelital y delimitación espacial de la zona de estudio	6
2	Tráfico vehicular en el Jirón Carlos F. Vivanco-Ayacucho	14
3	Congestionamiento vehicular en el centro histórico de Ayacucho	15
4	Relación entre flujo y densidad en un modelo macroscópico	20
5	Simulación microscópica del tráfico	21
6	Modelo mesoscópico: Pelotones de vehículos	22
7	Visión artificial	23
8	Diagrama de flujo de aprendizaje supervisado	24
9	Diagrama de flujo de aprendizaje no supervisado	24
10	Analogía de una matrioshka respecto a la inteligencia artificial	25
11	Modelo matemático de una neurona artificial	26
12	Arquitectura de una CNN	28
13	Convolución con un kernel de 3x3	31
14	Convoluciones a una matriz de entrada de 6x6 con un kernel de 3x3	31
15	Aplicación de la función de activación ReLU	32
16	Aplicación de un Max Pooling de 2x2	33
17	CNN típica y sus diferentes capas de procesamiento	35
18	Representación de la arquitectura Faster R-CNN	36
19	Representación de la arquitectura Yolo V.8	37
20	Interfaz de LabelMe	39
21	Ventajas y características de Google Colab	39
22	Representación del sistema de gestión semafórica inteligente	41
23	Diseño del brazo rígido de soporte	58
24	Uso del camión grúa para instalar las cámaras el Jirón Carlos F. Vivanco	58
25	Supervisión de la instalación de cámaras de vigilancia	59
26	Dirección del cableado de cámaras e internet a la caseta de serenazgo	59
27	Instalación del servicio de internet en el interior del observatorio	60
28	Enfoque,calidad y ángulo-Cámara 01	60
29	Enfoque,calidad y ángulo-Cámara 02	61
30	Fotografía registrada a las 12:41 horas por la cámara 01	61
31	Captura del flujo vehicular en entorno soleado	62
32	Captura del flujo vehicular en entorno nocturno	62
33	Captura del flujo vehicular en entorno lluvioso	62
34	Captura del flujo vehicular nocturno luces altas	63
35	Contraluz y sombras de casonas dificultan visibilidad del tráfico (11:20 am).	63
36	Dataset de 3000 imagenes en formato jpg	63
37	Valores UCP adaptados del PMUS-Huamanga	64
38	Etiquetado de Auto-Station Wagon-Perspectiva inclinada	66
39	Etiquetado de Auto-Perspectiva frontal	66
40	Etiquetado de MicroBus-Perspectiva frontal	66

41	Etiquetado de MicroBus-Perspectiva inclinada	67
42	Etiquetado de Motocicleta-Perspectiva lateral	67
43	Etiquetado de Motocicleta-Perspectiva frontal	67
44	Etiquetado de Camión pequeño-Perspectiva frontal	68
45	Etiquetado de Camión pequeño-Perspectiva inclinada	68
46	Etiquetado de Camioneta Pick UP-Perspectiva inclinada	68
47	Etiquetado de Mototaxi-Perspectiva Inclinada	69
48	Etiquetado de Camión Grande-Perspectiva inclinada	69
49	Etiquetado final de una fotografía	69
50	Archivos generados con extensión J.SON	70
51	Código de conversión de J.SON a archivos Yolo	70
52	Carpetas de archivos train y val	71
53	Contenido del archivo dataset.yamal	72
54	Gráfico de barras-150 épocas	73
55	Gráfico clustering o agrupamiento jerárquico-150 épocas	74
56	Gráfico mapa de calor X-Y-150 épocas	74
57	Gráfico mapa de calor Width-Height-150 épocas	75
58	Gráfico:Precision-Confidence Curve-150 épocas	75
59	Gráfico:Recall-Confidence Curve-150 época	76
60	Gráfico-Precisión: Recall-Confidence Curve-150 épocas	77
61	Validación de etiquetas-150 épocas	78
62	Validación de predicciones-150 épocas	78
63	Métricas de entrenamiento y validación-150 épocas	79
64	Gráfica:Análisis multidimensional-126 épocas	81
65	Gráfico:Precision-Confidence Curve-126 épocas	82
66	Gráfico-Recall-Confidence Curve-126 épocas	83
67	Gráfico-Precisión-Recall-Confidence Curve-126 épocas	83
68	Validación de predicciones-126 épocas	84
69	Contenido del archivo dataset.yamal	85
70	Métricas de entrenamiento y validación-150 épocas	86
71	Intersección semafórica-Jiron Carlos F. Vivanco y Jiron Sol	90
72	Intersección semafórica-Jiron Carlos F. Vivanco y Jiron Sol	91
73	Medición de los ciclos semafóricos-Jirón Carlos F. Vivanco con Jr. Sol	91
74	Inicializar modelo YOLO	93
75	Determinación de los bounding boxes	93
76	Asignación de valores UCP, para cada categoría (clase)	93
77	Filtrado temporal para reducir falsos positivos	94
78	Función asignar ID vehículo	94
79	Mejora de clasificación mediante confianza	95
80	Código de visualización	95
81	Detección, clasificación y conteo, realizado por el modelo	95

82	Detecciones y filtrado temporal	96
83	Contabilización de demanda total	97
84	Medición de los ciclos semafóricos-Jr. Sol con el Jirón Carlos F. Vivanco	97
85	Determinación del grado de saturación	97
86	Determinación del tiempo verde base	97
87	Incremento proporcional basado en densidad	98
88	Factor de escala por demanda total	98
89	Cálculo del tiempo verde final	98
90	Cálculo del tiempo ambar	99
91	Cálculo de los ciclos-semáforo 2	99
92	Determinación del ciclo total	99
93	Evaluación del nivel de servicio	99
94	Adaptación a tráfico ligero-velocidad alta de vehículos	101
95	Adaptación a tráfico medio-velocidad estandar de vehiculos	101
96	Adaptación a tráfico pesado-velocidad baja de vehículos	101
97	Deslumbramiento causado por las luces de los autos-lluvia intensa	102
98	Deslumbramiento causado por las luces de los autos-lluvia media	102
99	Deslumbramiento causado por las luces de los autos-lluvia tenue	102
100	Detección y conteo de vehículos bajo condiciones de sombras 11:20 am	103
101	Detección y conteo de vehículos bajo condiciones de sombras 14:55 pm	103
102	Seguimiento de vehículos detectado 09:06:28 am	104
103	Vehículo a punto de ocluirse por el microbus 09:06:30 am	104
104	Vehículo ocluido por el microbus pero registrado en el conteo 09:06:31 am	104
105	Grab 01-Tráfico ligero-05:44 am-amanecer nublado	105
106	Grab 02-Tráfico ligero-06:21 am-mañana nublada	105
107	Grab 03-Tráfico ligero-06:31 am-mañana nublada	105
108	Grab 04-Tráfico pesado-07:48 am-mañana nublada	106
109	Grab 05-Tráfico ligero-09:07 am-mañana soleada	106
110	Grab 06-Tráfico pesado-10:53 am-media mañana nublada	106
111	Grab 07-Tráfico pesado-11:14 am-media mañana soleada	107
112	Grab 08-Tráfico medio-11:20 am-media mañana soleada con sombras	107
113	Grab 09-Tráfico pesado-12:29 pm-medio día nublado	107
114	Grab 10-Tráfico pesado-12:44 pm-medio día nublado	108
115	Grab 11-Tráfico ligero-14:56 pm-tarde soleada con sombras	108
116	Grab 12-Tráfico pesado-15:56 pm-tarde soleada con sombras	108
117	Grab 13-Tráfico pesado-16:21 pm-tarde soleada con sombras	109
118	Grab 14-Tráfico medio-17:04 pm-atardcer nublado	109
119	Grab 15-Tráfico pesado-17:51 pm-atardcer nublado	109
120	Grab 16-Tráfico ligero-18:32 pm-anocheecer	110
121	Grab 17-Tráfico pesado-18:33 pm-anocheecer	110
122	Grab 18-Tráfico ligero-18:48 pm-noche	110

123	Grab 19-Tráfico pesado-18:51 pm-noche.	111
124	Grab 20-Tráfico pesado-18:56 pm-noche.	111
125	Grab 21-Tráfico pesado-19:52 pm-noche.	111
126	Grab 22-T.pesado-19:55 pm-lluvia intensa, viento y deslumbramiento.	112
127	Grab 23-Tráfico pesado-19:57 pm-noche lluvia intensa y deslumbramiento	112
128	Grab 24-Tráfico medio-20:18 pm-noche lluvia tenue y deslumbramiento	112
129	Grab 25-Tráfico medio-20:28 pm-noche lluvia tenue y deslumbramiento	113
130	Grab 26-Tráfico medio-20:31 pm-noche lluvia tenue y deslumbramiento	113
131	Grab 27-Tráfico ligero-20:33 pm-noche lluvia tenue y deslumbramiento	113
132	Grab 28-Tráfico ligero-20:34 pm-noche lluvia tenue y deslumbramiento	114
133	Grab 29-Tráfico pesado-21:05 pm-noche lluvia tenue y deslumbramiento	114
134	Grab 30-Tráfico pesado-21:09 pm-noche lluvia tenue y deslumbramiento	114
135	Grab 31-Tráfico ligero-22:02 pm-noche	115
136	Grab 32-Tráfico pesado-22:48 pm-noche lluvia tenue y deslumbramiento	115
137	Gráfico de barras-126 épocas	118
138	Gráfico clustering o agrupamiento jerárquico-126 épocas	119
139	Gráfico mapa de calor X-Y-126 épocas	120
140	Gráfico mapa de calor Width-Height-126 épocas	120
141	Gráfico: Precision-Confidence Curve-126 épocas	121
142	Gráfico-Recall-Confidence Curve-126 épocas	122
143	Gráfico-Precisión-Recall-Confidence Curve-126 épocas	122
144	Métricas de entrenamiento y validación-150 épocas	123
145	Detecciones y filtrado temporal en el conteo vehicular	126
146	Contabilización de demanda total	127
147	Normalización a estándares de ingeniería	127
148	Determinación del grado de saturación	127
149	Determinación del tiempo verde base	128
150	Incremento proporcional basado en la densidad	129
151	Factor de escala por demanda total	129
152	Cálculo del tiempo verde final	129
153	Cálculo del tiempo ámbar	130
154	Cálculo de los ciclos-semáforo 2	130
155	Determinación del ciclo total	131
156	Evaluación del nivel de servicio	131
157	Uso del GPU-T4	132
158	Montaje del google drive.	132
159	Instalación de ultralytics	132
160	Almacenamiento de vídeos en el Google Drive	133
161	Inicio del procesamiento-grabación 01	133
162	Ejecución final del procesamiento- 01	133
163	Ejecución final del procesamiento- 02	134

164	Videgrabación 01 exportada	134
165	Análisis resultado-detección y conteo en formato.CSV	135
166	Análisis resultado-optimización de los ciclos semaforicos en formato.CSV	135
167	Gráfico análisis completo de tráfico-grabación 01	135
168	Gráfico ciclos semaforicos optimizados-grabación 01	136
169	Vídeo exportado 01	137
170	Visualización del vídeo procesado	137
171	Análisis completo de tráfico-grab 01	138
172	Análisis completo de tráfico-grab 02	138
173	Análisis completo de tráfico-grab 03	138
174	Análisis completo de tráfico-grab 04	139
175	Análisis completo de tráfico-grab 05	139
176	Análisis completo de tráfico-grab 06	139
177	Análisis completo de tráfico-grab 07	140
178	Análisis completo de tráfico-grab 08	140
179	Análisis completo de tráfico-grab 09	140
180	Análisis completo de tráfico-grab 10	141
181	Análisis completo de tráfico-grab 11	141
182	Análisis completo de tráfico-grab 12	141
183	Análisis completo de tráfico-grab 13	142
184	Análisis completo de tráfico-grab 14	142
185	Análisis completo de tráfico-grab 15	142
186	Análisis completo de tráfico-grab 16	143
187	Análisis completo de tráfico-grab 17	143
188	Análisis completo de tráfico-grab 18	143
189	Análisis completo de tráfico-grab 19	144
190	Análisis completo de tráfico-grab 20	144
191	Análisis completo de tráfico-grab 21	144
192	Análisis completo de tráfico-grab 22	145
193	Análisis completo de tráfico-grab 23	145
194	Análisis completo de tráfico-grab 24	145
195	Análisis completo de tráfico-grab 25	146
196	Análisis completo de tráfico-grab 26	146
197	Análisis completo de tráfico-grab 27	146
198	Análisis completo de tráfico-grab 28	147
199	Análisis completo de tráfico-grab 29	147
200	Análisis completo de tráfico-grab 30	147
201	Análisis completo de tráfico-grab 31	148
202	Análisis completo de tráfico-grab 32	148
203	Ciclos semaforicos-grab 01-Densidad UCP: 1.07 UCP/km/h	150
204	Ciclos semaforicos-grab 02-Densidad UCP: 1.09 UCP/km/h	150

205	Ciclos semafóricos-grab 03-Densidad UCP: 0.67 UCP/km/h	150
206	Ciclos semafóricos-grab 04-Densidad UCP: 1.83 UCP/km/h	151
207	Ciclos semafóricos-grab 05-Densidad UCP: 0.69 UCP/km/h	151
208	Ciclos semafóricos-grab 06-Densidad UCP: 1.86 UCP/km/h	151
209	Ciclos semafóricos-grab 07-Densidad UCP: 2.17 UCP/km/h	152
210	Ciclos semafóricos-grab 08-Densidad UCP: 1.82 UCP/km/h	152
211	Ciclos semafóricos-grab 09-Densidad UCP: 2.12 UCP/km/h	152
212	Ciclos semafóricos-grab 10-Densidad UCP: 2.02 UCP/km/h	153
213	Ciclos semafóricos-grab 11-Densidad UCP: 1.21 UCP/km/h	153
214	Ciclos semafóricos-grab 12-Densidad UCP: 2.17 UCP/km/h	153
215	Ciclos semafóricos-grab 13-Densidad UCP: 2.07 UCP/km/h	154
216	Ciclos semafóricos-grab 14-Densidad UCP: 1.51 UCP/km/h	154
217	Ciclos semafóricos-grab 15-Densidad UCP: 2.31 UCP/km/h	154
218	Ciclos semafóricos-grab 16-Densidad UCP: 0.82 UCP/km/h	155
219	Ciclos semafóricos-grab 17-Densidad UCP: 1.94 UCP/km/h	155
220	Ciclos semafóricos-grab 18-Densidad UCP: 0.64 UCP/km/h	155
221	Ciclos semafóricos-grab 19-Densidad UCP: 1.62 UCP/km/h	156
222	Ciclos semafóricos-grab 20-Densidad UCP: 1.45 UCP/km/h	156
223	Ciclos semafóricos-grab 21-Densidad UCP: 2.39 UCP/km/h	156
224	Ciclos semafóricos-grab 22-Densidad UCP: 1.88 UCP/km/h	157
225	Ciclos semafóricos-grab 23-Densidad UCP: 1.58 UCP/km/h	157
226	Ciclos semafóricos-grab 24-Densidad UCP: 1.13 UCP/km/h	157
227	Ciclos semafóricos-grab 25-Densidad UCP: 1.12 UCP/km/h	158
228	Ciclos semafóricos-grab 26-Densidad UCP: 0.77 UCP/km/h	158
229	Ciclos semafóricos-grab 27-Densidad UCP: 0.46 UCP/km/h	158
230	Ciclos semafóricos-grab 28-Densidad UCP: 0.89 UCP/km/h	159
231	Ciclos semafóricos-grab 29-Densidad UCP: 1.46 UCP/km/h	159
232	Ciclos semafóricos-grab 30-Densidad UCP: 0.90 UCP/km/h	159
233	Ciclos semafóricos-grab 31-Densidad UCP: 0.69 UCP/km/h	160
234	Ciclos semafóricos-grab 32-Densidad UCP: 0.87 UCP/km/h	160
235	Comparativa sistema estandar vs optimizado-grab 01	162
236	Comparativa sistema estandar vs optimizado-grab 02	162
237	Comparativa sistema estandar vs optimizado-grab 03	162
238	Comparativa sistema estandar vs optimizado-grab 04	163
239	Comparativa sistema estandar vs optimizado-grab 05	163
240	Comparativa sistema estandar vs optimizado-grab 06	163
241	Comparativa sistema estandar vs optimizado-grab 07	164
242	Comparativa sistema estandar vs optimizado-grab 08	164
243	Comparativa sistema estandar vs optimizado-grab 09	164
244	Comparativa sistema estandar vs optimizado-grab 10	165
245	Comparativa sistema estandar vs optimizado-grab 11	165

246	Comparativa sistema estandar vs optimizado-grab 12	165
247	Comparativa sistema estandar vs optimizado-grab 13	166
248	Comparativa sistema estandar vs optimizado-grab 14	166
249	Comparativa sistema estandar vs optimizado-grab 15	166
250	Comparativa sistema estandar vs optimizado-grab 16	167
251	Comparativa sistema estandar vs optimizado-grab 17	167
252	Comparativa sistema estandar vs optimizado-grab 18	167
253	Comparativa sistema estandar vs optimizado-grab 19	168
254	Comparativa sistema estandar vs optimizado-grab 20	168
255	Comparativa sistema estandar vs optimizado-grab 21	168
256	Comparativa sistema estandar vs optimizado-grab 22	169
257	Comparativa sistema estandar vs optimizado-grab 23	169
258	Comparativa sistema estandar vs optimizado-grab 24	169
259	Comparativa sistema estandar vs optimizado-grab 25	170
260	Comparativa sistema estandar vs optimizado-grab 26	170
261	Comparativa sistema estandar vs optimizado-grab 27	170
262	Comparativa sistema estandar vs optimizado-grab 28	171
263	Comparativa sistema estandar vs optimizado-grab 29	171
264	Comparativa sistema estandar vs optimizado-grab 30	171
265	Comparativa sistema estandar vs optimizado-grab 31	172
266	Comparativa sistema estandar vs optimizado-grab 32	172
267	Instalación de las cámaras de investigación	184
268	Preparación del camión grua	184
269	Despliegue del brazo hidráulico	184
270	Despliegue del brazo hidráulico, vista principal	185
271	Supervisión de la instalación.	185
272	Instalación de los dispositivos a la caja de control electrico	186
273	Montaje del brazo rígido de soporte	186
274	Dirección del cableado a la caseta de observatorio	187
275	Vista final de la cámara de investigación	187

LISTA DE CUADROS

1	Comparativa de modelos de simulación de tráfico	22
2	Proceso de convoluciones a una imagen de 48x48 píxeles	34
3	Herramientas de software utilizadas	57
4	Definición de categorías (clases)	65
5	Comparativa YOLOv8n (Nano) con YOLOv8m (Medium).	72
6	Distribución de instancias por categoría de vehículo	73
7	Resultados mAP50 y mAP50-95, 150 épocas	81
8	Tiempos de Procesamiento-150 épocas.	81
9	Resultados mAP50 y mAP50-95, 126 épocas	88
10	Tiempos de Procesamiento-126 épocas.	88
11	Comparativa Precisión (P) , Recall (R), mAP50 , mAP50-95	89
12	Comparativa tiempo de procesamiento	89
13	Tiempos y características de los ciclos semafóricos	91
14	Resultados de detección, clasificación y conteo de vehículos en variable condición	116
15	Distribución de instancias por categoría de vehículo	118
16	Resultados mAP50 y mAP50-95, 126 épocas	124
17	Tiempos de Procesamiento-126 épocas	124
18	Análisis completo de tráfico vehicular	149
19	Resultados de los ciclos semafóricos optimizados en función de la densidad (UCP)	161

GLOSARIO

AIMA	Algoritmo de inteligencia y movilidad adaptativa que optimiza la duración de ciclos semafóricos en función de la densidad vehicular.
Bounding Box	Rectángulo delimitador que localiza y enmarca un objeto detectado en una imagen durante el procesamiento de visión artificial.
CNN	Red Neuronal Convolutiva, arquitectura de aprendizaje profundo especializada en procesamiento de imágenes y reconocimiento de patrones visuales.
Densidad UCP	Cantidad de Unidades de Coche Patrón por unidad de longitud y tiempo (UCP/km/h), utilizada para cuantificar la saturación vial.
Early Stopping	Técnica que detiene automáticamente el entrenamiento cuando deja de mejorar el rendimiento, evitando el sobreajuste.
Filtrado Temporal	Sistema que elimina falsos positivos verificando la consistencia de detecciones a lo largo de múltiples fotogramas consecutivos.
Grado de Saturación	Relación entre la densidad vehicular y la capacidad ideal de una vía, expresada como proporción (0-1).
IoU	Intersection over Union, métrica que evalúa la precisión de una detección comparando el área de superposición entre la predicción y la etiqueta real.
Kernel	Matriz numérica que se desliza sobre una imagen para extraer características durante la operación de convolución.
LabelMe	Herramienta de anotación de imágenes utilizada para crear conjuntos de datos de entrenamiento para modelos de aprendizaje profundo.
mAP	Mean Average Precision, métrica que evalúa el rendimiento de modelos de detección de objetos, incorporando precisión y exhaustividad.
Matriz de Confusión	Tabla que visualiza el rendimiento de un algoritmo de clasificación, mostrando verdaderos/falsos positivos y negativos.
Pooling	Operación que reduce la dimensionalidad espacial de una representación, conservando la información más relevante.
Recall	Exhaustividad o sensibilidad, mide la proporción de positivos reales correctamente identificados por el modelo.
ReLU	Rectified Linear Unit, función de activación que introduce no linealidad en las redes neuronales, transformando valores negativos a cero.
Sobreajuste	Fenómeno donde un modelo se adapta excesivamente a los datos de entrenamiento, perdiendo capacidad de generalización.
UCP	Unidad de Coche Patrón, valor asignado a cada tipo de vehículo según su impacto en el flujo de tráfico.
YOLO	You Only Look Once, algoritmo de detección de objetos en tiempo real que analiza la imagen completa en una sola pasada.

ACRÓNIMOS

API	Application Programming Interface (Interfaz de Programación de Aplicaciones), conjunto de protocolos y herramientas para construir aplicaciones de software.
CNN	Convolutional Neural Network (Red Neuronal Convolucional), arquitectura de aprendizaje profundo especializada en procesamiento visual.
DFL	Distribution Focal Loss, función de pérdida avanzada utilizada en modelos YOLO para mejorar la precisión de localización.
FPS	Frames Per Second (Fotogramas Por Segundo), medida de velocidad de procesamiento en sistemas de visión artificial.
GPU	Graphics Processing Unit (Unidad de Procesamiento Gráfico), acelerador hardware para cálculos paralelos en entrenamiento de redes neuronales.
HCM	Highway Capacity Manual, documento de referencia en ingeniería de tránsito para análisis de capacidad y nivel de servicio.
IoU	Intersection over Union, métrica para evaluar la precisión de detección en modelos de visión artificial.
ITS	Intelligent Transportation Systems (Sistemas Inteligentes de Transporte), conjunto de tecnologías que mejoran la seguridad y eficiencia del transporte.
LWR	Lighthill-Whitham-Richards, modelo matemático fundamental para describir la dinámica del flujo vehicular.
mAP	mean Average Precision, métrica estándar para evaluar el rendimiento de algoritmos de detección de objetos.
NMS	Non-Maximum Suppression, algoritmo para eliminar detecciones redundantes en modelos de visión artificial.
PMUS	Plan de Movilidad Urbana Sostenible, instrumento de planificación del transporte urbano.
ReLU	Rectified Linear Unit, función de activación ampliamente utilizada en redes neuronales artificiales.
RNA	Redes Neuronales Artificiales, modelos computacionales inspirados en el funcionamiento del cerebro humano.
SGD	Stochastic Gradient Descent (Descenso de Gradiente Estocástico), algoritmo de optimización para el entrenamiento de modelos de aprendizaje profundo.
TPU	Tensor Processing Unit, circuito integrado de aplicación específica (ASIC) para acelerar el aprendizaje automático.
UCP	Unidad de Coche Patrón, medida estandarizada para homogeneizar diferentes tipos de vehículos en análisis de tráfico.
YOLO	You Only Look Once, algoritmo de detección de objetos en tiempo real que analiza la imagen completa en una única pasada.

LISTA DE SÍMBOLOS

a	Aceleración o desaceleración de un vehículo, medida en m/s^2 .
α	Parámetro de ajuste en funciones de activación como Leaky ReLU: $f(x) = \max(\alpha x, x)$.
C	Capacidad vial expresada en vehículos por hora por carril (veh/h/carril).
d	Demora o tiempo de retardo en una intersección semaforizada, medido en segundos por vehículo (s/veh).
Δt	Incremento de tiempo verde en función de la densidad vehicular.
η	Tasa de aprendizaje (learning rate) en algoritmos de optimización para redes neuronales.
$f(x)$	Función de activación en redes neuronales, como ReLU: $f(x) = \max(0, x)$.
$F1$	Medida F1-score, media armónica entre precisión y recall: $F1 = 2 \times \frac{P \times R}{P + R}$.
g	Tiempo de verde efectivo en un ciclo semafórico, medido en segundos.
GS	Grado de saturación, relación entre la demanda vehicular y la capacidad vial.
IoU	Intersection over Union, calculado como: $IoU = \frac{rea\ de\ intersección}{rea\ de\ unión}$.
k	Densidad vehicular expresada en vehículos por kilómetro (veh/km).
K	Kernel o filtro convolucional utilizado en redes neuronales.
$\mathcal{L}$	Función de pérdida (loss function) para medir el error del modelo durante el entrenamiento.
P	Precisión en métricas de evaluación del modelo de detección.
q	Flujo vehicular expresado en vehículos por hora (veh/h).
R	Recall o exhaustividad en métricas de evaluación del modelo de detección.
ρ	Densidad normalizada UCP por kilómetro por hora (UCP/km/h).
$\sigma(x)$	Función sigmoide utilizada como activación: $\sigma(x) = \frac{1}{1+e^{-x}}$.
v	Velocidad vehicular, expresada en kilómetros por hora (km/h).
w_i	Peso sináptico de la conexión i -ésima en una red neuronal artificial.
X	Grado de saturación, relación volumen/capacidad (v/c).

TESIS

1. PLANTEAMIENTO DEL PROBLEMA

1.1. Descripción del problema

La congestión vehicular es uno de los principales problemas con la que conviven muchas ciudades en el mundo. Abordar la congestión vehicular no admite una solución universal, ya que su naturaleza intrínsecamente compleja se manifiesta de forma única en cada entorno urbano, influenciada por factores distintivos como la configuración de sus vías, la organización de su transporte público, los patrones de flujo de vehículos, su señalización vial y sus canales de comunicación, entre otros elementos.

Montoya Calderón (2021) señala que en Perú el parque automotor ha experimentado un crecimiento significativo, casi duplicándose en una década, ya que pasó de 1,640,970 vehículos en 2008 a 2,894,327 en 2018, fenómeno atribuido principalmente al incremento poblacional del país. El congestionamiento del tránsito ha escalado hasta convertirse en una problemática prioritaria que demanda atención inmediata, tanto por sus múltiples impactos negativos como por la insuficiencia de las estrategias de mitigación implementadas hasta la fecha.

En la ciudad de Ayacucho, la congestión vehicular, es uno de los principales desafíos que enfrentan las autoridades públicas. Este problema tiene como resultado el malestar generalizado entre los ciudadanos, provocado por el desorden, los niveles de contaminación y la informalidad presentes en el sistema de transporte local.

La expansión económica regional, junto con los movimientos migratorios internos durante los años noventa y el desarrollo urbano acelerado y carente de planificación, se han visto complementados por recientes flujos migratorios que no se tenían previstos, destacando particularmente la llegada de ciudadanos venezolanos. Estos fenómenos convergentes han propiciado un aumento sustancial en la flota de vehículos dedicados al transporte público, con predominancia del servicio de motos y taxis.

La movilidad urbana en Ayacucho enfrenta desafíos significativos. Las rutas no poseen una distribución adecuada de paraderos, lo cual origina, que muchos de los buses de las diferentes rutas de transporte público se estacionen en cualquier calle o avenida, desde esquinas hasta la parte media de la cuadra.

A lo antes mencionado, se le suma la presencia de sistemas de semaforización convencionales:

- Como se señala en Municipalidad Provincial de Huamanga (2020, p. 390), “La ciudad de Ayacucho no cuenta con un sistema de semaforización centralizado. Lo que existe es básicamente un grupo de intersecciones semaforizadas, principalmente alrededor de la parte histórica de la ciudad”.
- De acuerdo con Municipalidad Provincial de Huamanga (2022, p. 203), la infraestructura de control de tráfico presenta deficiencias críticas en su sistema

semafórico: de las 48 intersecciones semaforizadas, 36 requieren mantenimiento urgente y 12 necesitan completa reestructuración. Los equipos operan de manera aislada, sin ningún tipo de centralización o sincronización entre intersecciones, lo que genera un ineficiente patrón de “ola roja” que obstaculiza el flujo vehicular. Esta problemática se agrava por las desprogramaciones frecuentes de los dispositivos y su operación con ciclos de duración fija basados en estudios de tráfico realizados durante períodos excesivamente breves, que no reflejan la variabilidad real de los flujos vehiculares a lo largo del día.

El empleo de sistemas semafóricos con intervalos de tiempo predeterminados, conlleva una serie de problemas y un derroche considerable de recursos fundamentales como el tiempo, energía y combustible (debido incremento de paradas y reinicios de los vehículos), estos sistemas asignan tiempo de color rojo aun cuando el tramo no necesita dicho tiempo o peor cuando el tramo no tiene vehículos en espera. Abbas et al. (2023, p. 2) señalan que “El tráfico controlado por intervalos de tiempo fijos es una de las principales causas de atascos”. Esta circunstancia subraya una deficiencia esencial en la administración del tránsito local.

La organización actual del tráfico vehicular en el centro histórico de Ayacucho impide una óptima integración del flujo con las principales vías arteriales y secundarias a las que sus calles convergen. El Jirón Carlos F. Vivanco se destaca como un punto especialmente conflictivo, ya que sus vías estrechas resultan insuficientes para absorber la demanda vehicular en las horas de mayor afluencia, obstaculizando la implementación de un sistema de regulación de tráfico eficiente, lo cual se evidencia en un tránsito congestionado y de circulación lenta.

Las consecuencias de la congestión vehicular se miden en función de pérdida de tiempo e incremento de estrés para las personas que se movilizan por la ciudad, lo cual se refleja en pérdidas económicas y problemas de salud para la sociedad.

Para ilustrar el efecto económico, solo en Estados Unidos, Pishue (2020) señala que la congestión vehicular significó una pérdida de 88 billones de dólares en el año 2019, mientras que en Perú la pérdida alcanzó los 27 000 millones de soles en el año 2017 TRANSITEMOS (2017). Estas alarmantes cifras se deben principalmente a la pérdida de productividad de los trabajadores que pasan tiempo en el tráfico, al consumo adicional de combustible y al incremento del costo de transporte de bienes a través de áreas congestionadas.

Actualmente, la Municipalidad Provincial de Huamanga, junto con el Ministerio de Transportes y Comunicaciones y el programa PROMOVILIDAD, está implementando el Plan de Movilidad Urbana Sostenible (PMUS-Huamanga) para mejorar la movilidad provincial. Este plan incluye estrategias de coordinación semafórica (olas verdes) que buscan optimizar los flujos vehiculares, sin embargo, la efectividad de estas estrategias es cuestionable, ya que su implementación sin un análisis integral puede desplazar la congestión a vías adyacentes, ocasionando repercusiones de congestión en estas para optimizar el flujo vehicular.

1.2. Delimitación del problema

1.2.1. Espacial (geográfica)

El área de investigación se encuentra localizada en las vías correspondientes al Jirón Carlos F. Vivanco y la cuadra final del Jirón Sol del distrito de Ayacucho. Se sitúa en el huso 18 y zona L de la proyección UTM, hemisferio Sur, con referencia al Datum WGS84.

La ejecución de la investigación se realizó en:

- **Región:** Ayacucho.
- **Provincia:** Huamanga
- **Distrito:** Ayacucho
- **Región Natural:** Sierra



Figura 1: Vista satelital y delimitación espacial de la zona de estudio
Fuente: Elaboración propia

1.2.2. Temporal

Esta investigación se circunscribe temporalmente al intervalo que va desde setiembre de 2024 hasta abril de 2025. En dicho periodo se ejecutó la recolección de información fundamental, seguida del procesamiento analítico y la subsecuente interpretación de los hallazgos derivados del estudio.

1.2.3. Temática y unidad de análisis

- **Temática:** La temática de esta investigación se inscribe dentro del área de transportes, específicamente en la ingeniería de tránsito urbano, y se enfoca en la aplicación de tecnologías avanzadas de visión artificial para la gestión adaptativa del tráfico.
- **Unidad de Análisis :** La unidad de análisis de esta investigación es el flujo vehicular en el Jirón Carlos F. Vivanco de la ciudad de Ayacucho, específicamente enfocado en los vehículos que transitan por esta vía, categorizados según su tipo y características.

Esta unidad de análisis es observada y procesada a través de imágenes capturadas del tránsito vehicular, que sirven como datos primarios para los algoritmos de detección y clasificación.

1.3. Formulación del problema

1.3.1. Problema general

¿De qué manera el modelo de tráfico vehicular basado en Redes Neuronales Artificiales (RNA) ,reduce la congestión vehicular en el Jirón Carlos F. Vivanco, distrito de Ayacucho, 2024?

1.3.2. Problemas específicos

1. ¿Cómo el diseño del modelo basado en Redes Neuronales Artificiales (RNA) permite ajustar una arquitectura para la detección, clasificación y conteo eficiente de vehículos en condiciones heterogéneas, que incluyen tráfico variable, diversas condiciones ambientales (precipitaciones, iluminación solar variable, sombras proyectadas) y entornos nocturnos con visibilidad limitada?
2. ¿En qué medida el entrenamiento del modelo basado en Redes Neuronales Artificiales (RNA) permite alcanzar un equilibrio óptimo entre la precisión en la detección, la exhaustividad en el reconocimiento de vehículos y la robustez contra el sobreajuste?
3. ¿De qué manera la implementación del modelo basado en Redes Neuronales Artificiales (RNA) permite desarrollar un algoritmo , que optimice la duración de los ciclos semafóricos en función de la densidad vehicular bajo condiciones variables de tráfico?

1.4. Justificación e importancia

1.4.1. Conveniencia

Esta investigación es altamente conveniente en el contexto actual, ya que aborda directamente la problemática crítica de los sistemas semafóricos deficientes en Ayacucho. El modelo propuesto ofrece una alternativa tecnológica viable basada en redes neuronales que supera las limitaciones de los semáforos con intervalos de tiempo predeterminados, identificados como una de las principales causas de congestión vehicular.

El sistema sirve para optimizar el flujo vehicular en el Jirón Carlos F. Vivanco mediante un sistema inteligente que, a diferencia de los semáforos convencionales, ajusta los ciclos semafóricos según la densidad vehicular, lo que permite superar las limitaciones estructurales de las vías estrechas que resultan insuficientes para absorber el flujo vehicular.

1.4.2. Relevancia social

La trascendencia social radica en la mejora directa de la calidad de vida de la población ayacuchana al mitigar los problemas que genera la congestión vehicular. Además, contrarresta las consecuencias del crecimiento acelerado del parque automotor.

Se beneficiarán directamente los conductores y pasajeros que transitan por el Jirón Carlos F. Vivanco, al reducirse sus tiempos de espera y desplazamiento. Indirectamente, toda la población ayacuchana se beneficiará por la disminución de la contaminación ambiental, la reducción del estrés asociado al tráfico y la optimización de recursos económicos (menos consumo de combustible y mayor productividad por reducción de tiempos de viaje).

1.4.3. Aplicaciones prácticas

Este modelo aborda tres problemas reales y urgentes: La ineficiencia de los semáforos con ciclos fijos que operan sin sincronización entre ellos, generando predominantemente un patrón de “ola roja”; el congestionamiento vehicular en una vía crítica del centro histórico de Ayacucho, caracterizada por su estrechez e incapacidad para absorber la creciente demanda vehicular; y el desperdicio de recursos (tiempo, combustible, energía) junto con la contaminación ambiental resultante de los prolongados tiempos de espera innecesarios.

1.4.4. Unidad metodológica

El proyecto desarrolla un sistema innovador de visión artificial que constituye en sí mismo un instrumento avanzado para la recolección, procesamiento y análisis automático de datos sobre flujos vehiculares. Este sistema no solo detecta y clasifica vehículos, sino que genera las bases del algoritmo para la optimización de los ciclos semaforicos, específicos del contexto ayacuchano, información actualmente inexistente que será valiosa para futuras investigaciones y decisiones en una implementación de semaforización inteligente.

1.4.5. Valor teórico

Esta investigación llena un vacío significativo en el conocimiento sobre la aplicación de redes neuronales convolucionales para la gestión de tráfico en centros históricos, con configuraciones viales particulares y altos niveles de informalidad en el transporte, un contexto poco estudiado en la literatura científica actual.

Esta investigación genera valiosos datos sobre patrones de movilidad y comportamiento vehicular en Ayacucho que posibilitan nuevas hipótesis sobre optimización de sistemas de transporte urbano. Los resultados y metodologías desarrollados podrán generalizarse a otras intersecciones semaforicas críticas de Ayacucho y a ciudades intermedias peruanas con características similares .

1.5. Limitaciones de la investigación

A pesar de que esta investigación está bien diseñada y utiliza metodologías avanzadas, enfrenta ciertas limitaciones que deben ser reconocidas:

- **Limitaciones tecnológicas:** Debido a que no es factible económicamente la implementación de un piloto de semaforización inteligente, en la presente investigación se realiza un modelo de simulación.
- **Impacto humano y errores:** A pesar de la automatización, la intervención humana en la fase de etiquetado y validación de datos puede introducir errores. Además, el proceso de ajuste y entrenamiento del modelo depende en gran medida de la experiencia y

habilidades del equipo de investigación.

- **Semaforo en una interseccion vial:** La investigación se desarrolló considerando la asignación de los ciclos semafóricos en una intersección vial, no considera semáforos en óvalo o rotonda. Siendo el tráfico vehicular un tema tan complejo por los innumerables tipos de escenarios que se presentan en cada tramo vehicular por cada intervalo de tiempo.

1.6. Objetivos de la investigación

1.6.1. Objetivo general

Desarrollar el modelo de tráfico vehicular, basado en Redes Neuronales Artificiales (RNA), que permita reducir, la congestión vehicular en el Jirón Carlos F. Vivanco, distrito de Ayacucho, 2024.

1.6.2. Objetivos específicos

1. Desarrollar el diseño del modelo basado en Redes Neuronales Artificiales (RNA), que permita ajustar una arquitectura para la detección, clasificación y conteo eficiente de vehículos en condiciones heterogéneas, que incluyen tráfico variable, diversas condiciones ambientales (precipitaciones, iluminación solar variable, sombras proyectadas) y entornos nocturnos con visibilidad limitada.
2. Simular el entrenamiento del modelo basado en Redes Neuronales Artificiales (RNA), para lograr un equilibrio óptimo entre la precisión en la detección, la exhaustividad en el reconocimiento de vehículos y la robustez contra el sobreajuste.
3. Determinar como la implementación del modelo basado en Redes Neuronales Artificiales (RNA) permite desarrollar un algoritmo, que optimice la duración de los ciclos en función de la densidad vehicular bajo condiciones variables de tráfico.

2. MARCO TEÓRICO

2.1. Antecedentes

2.1.1. Investigaciones internacionales

C. Wang et al. (2025) proponen un marco de reconocimiento de congestión vehicular basado en redes neuronales convolucionales que funciona en diferentes escenarios (diurno, nocturno, lluvioso y con niebla). Desarrollaron una red de desempañado por fusión controlada basada en atención residual (RAGFNet) para procesar imágenes con niebla, combinándola con YOLOv8 y extracción de características locales. Su modelo alcanzó una precisión del 98,2 %, una recuperación del 97,7 % y un valor F1 del 98,6 %. La aplicabilidad se validó mediante evaluación en tiempo real y visualización de áreas congestionadas con Grad-CAM.

Lin y Lee (2024) abordan los problemas de congestión e infracciones de tránsito en Taiwán mediante un estudio comparativo de diferentes versiones del algoritmo YOLO para la detección de vehículos. Su investigación examina exhaustivamente las versiones YOLOv5, YOLOv6, YOLOv7 y YOLOv8, comparando sus resultados bajo condiciones idénticas. Para mejorar la precisión, complementan conjuntos de datos públicos con imágenes reales de cámaras de tablero y realizan un etiquetado manual con Labelimg. Los modelos resultantes logran una precisión media promedio (mAP) de hasta el 99,5 %, posicionando esta tecnología como fundamental para el futuro desarrollo de vehículos autónomos y ciudades inteligentes.

Duc et al. (2024) sintetizaron un método para gestionar la congestión urbana mediante el control dinámico de semáforos basado en la densidad del tráfico. Su sistema implementa el modelo YOLOv8 para analizar imágenes de cámaras de vigilancia, identificar vehículos y ajustar automáticamente los tiempos de los semáforos. La evaluación del sistema muestra una precisión de detección notable, con un mAP50 de hasta 97 %, y sus capacidades de conteo vehicular y control de semáforos han sido probadas en diversos escenarios de tráfico.

Xu et al. (2024) desarrollaron un modelo mejorado de detección de objetivos denominado YOLO-HyperVision (YOLO-HV), que integra la estructura de Transformador de Visión (ViT) en YOLOv5 para abordar desafíos de detección vehicular desde drones. Los autores combinan las ventajas de detección multiescala del ViT con la capacidad de sesgo inductivo de las redes CNN, incorporando módulos residuales multiescala y de mejora de correlación contextual. En experimentos con el conjunto de datos VisDrone, el modelo YOLO-HV logró aumentar la precisión media promedio (mAP) en un 3,3 % comparado con redes convolucionales puras de tamaño similar, demostrando una mejora significativa en la detección de vehículos y flujo de tráfico en imágenes aéreas donde los objetivos son pequeños y con grandes diferencias de escala.

Kiran et al. (2024) abordan el problema de la detección vehicular en condiciones meteorológicas variables mediante un modelo YOLOv4 mejorado que incorpora técnicas como Retinex Multiescala, la Transformada Wavelet Compleja de Árbol Dual (DTCWT) y Redes Neuronales Acopladas por Pulsos (PCNN). Su propuesta alcanza un mAP del 91,09 % a 35 FPS, superando los métodos existentes en diversos escenarios como condiciones soleadas, nocturnas, nubladas y lluviosas.

Naithani y Jain (2024) presentan un sistema conceptual de semáforos que utiliza reconocimiento de imágenes en tiempo real y aprendizaje automático para gestionar eficientemente el tráfico en intersecciones urbanas. Su propuesta emplea cámaras de alta resolución y modelos de detección como YOLO o Faster R-CNN para contabilizar vehículos y ajustar dinámicamente la duración de los semáforos, incluyendo una función para detectar y dar prioridad a vehículos de emergencia mediante tecnología RF.

Pudaruth et al. (2024) sintetizan una solución innovadora basada en redes neuronales de aprendizaje profundo y visión artificial para abordar la congestión vial. Su sistema utiliza modelos YOLO entrenados con 2800 fotogramas para detectar, rastrear y contabilizar diferentes tipos de vehículos en tiempo real, logrando una precisión media de conteo del 96,1 % y de clasificación del 94,4 %. El sistema también estima velocidades vehiculares y determina el flujo de tráfico con una precisión del 93,9 %, ofreciendo una alternativa moderna y económica a los métodos manuales convencionales.

Pawade et al. (2024) abordan el problema de la gestión del tráfico urbano mediante un sistema que implementa el algoritmo YOLO para el procesamiento de imágenes en tiempo real. Su solución incorpora cámaras ESP32 con chips FTDI para capturar y analizar imágenes de intersecciones, y utiliza un servomotor para rotar la cámara y cubrir los cuatro carriles. El sistema ajusta dinámicamente los semáforos basándose en datos de densidad vehicular en tiempo real, con el objetivo de gestionar eficientemente el flujo de tráfico y reducir la congestión, especialmente crítica para vehículos de emergencia como ambulancias.

Sivaganesan et al. (2024) abarcan el creciente problema de la congestión vehicular, especialmente crítico en intersecciones donde los sistemas de semáforos tradicionales resultan inadecuados frente al volumen actual de vehículos. Su propuesta implementa tecnologías avanzadas de visión artificial y aprendizaje automático, específicamente la red neuronal convolucional YOLO (You Only Look Once), para analizar datos de tráfico en tiempo real. El sistema evalúa factores como el tiempo promedio de espera y la cantidad de vehículos en fila para optimizar dinámicamente las fases de los semáforos, con el objetivo de crear un flujo de tráfico más coordinado y eficiente, reduciendo los tiempos de espera y mejorando la movilidad urbana.

Abbas et al. (2023) investigaron la problemática de los sistemas manuales de semáforos, predominantes en países en desarrollo, que generan ineficiencias y desperdicio de recursos al no poder tomar decisiones en tiempo real. En respuesta, propusieron un algoritmo para automatizar los semáforos basándose en la densidad vehicular en tiempo real, obtenida de cámaras de circuito cerrado adyacentes a las señales. El algoritmo utiliza

Faster R-CNN para la detección de vehículos y, para validarlo, crearon un conjunto de datos local con transmisiones en vivo de cámaras de Punjab Safe City, en colaboración con la policía local. Los resultados del algoritmo propuesto demostraron una alta precisión tanto en la clasificación (96.6 %) como en la detección de vehículos (95.7 %), manteniendo un rendimiento robusto en diferentes condiciones de luz y superando a metodologías existentes en diversas métricas de evaluación.

2.1.2. Investigaciones nacionales

Como señalan Apestegui Florentino y Caselli Gismondi (2024), la gestión del tráfico vehicular constituye un desafío significativo en las ciudades modernas, principalmente por la configuración de semáforos con tiempos fijos que no se adaptan a las condiciones reales del flujo vehicular. Su investigación propone un sistema inteligente para la gestión de semáforos en tiempo real que considera la velocidad y densidad vehicular mediante un algoritmo heurístico. Los resultados experimentales, basados en 15000 escenarios simulados, demostraron una reducción del 18.3 % en el tiempo del ciclo, alcanzando 47 ciclos/hora en comparación con los 39 ciclos/hora de los sistemas convencionales con fases fijas.

De acuerdo con Ruiz-Choque et al. (2023), la congestión del tráfico interrumpe significativamente nuestros desplazamientos diarios, causando a menudo retrasos e impidiéndonos llegar a nuestros destinos puntualmente. Una de las principales causas de esta congestión es la cantidad de vehículos que supera la capacidad de las carreteras, especialmente en horas punta, estudios previos se han centrado principalmente en el mapeo de zonas de congestión urbana y la predicción de patrones futuros, sin embargo; comprender las causas fundamentales de la congestión es crucial para idear soluciones prácticas. Su investigación aborda un sistema de semáforo inteligente impulsado por inteligencia artificial, aprovechando el versátil lenguaje de programación Python, ampliamente reconocido por su adaptabilidad en la creación de soluciones de IA, se emplearon redes neuronales convolucionales (CNN) para analizar imágenes de peatones y vehículos en tiempo real. Permitieron que los semáforos prioricen el flujo de tráfico de forma óptima, minimizando potencialmente los tiempos de espera y aliviando la congestión, evidenciándose en resultados, el semáforo inteligente redujo el tiempo de cruce de vehículos en la intersección de 10 a 6 segundos y aumentó el rendimiento a 33 vehículos por minuto, en comparación con los 21 vehículos del semáforo convencional. El algoritmo del sistema identifica el flujo vehicular, optimizando los cambios de semáforo para una mayor eficiencia.

Gonzales del Valle Romero y Neyra Espinoza (2022) implementaron las redes neuronales convolucionales YOLO v5 y Faster RCNN, aplicando transfer learning mediante congelamiento de capas y fine tuning respectivamente, utilizando un dataset de 460 imágenes. Tras evaluar la precisión, los FPS, el porcentaje de error promedio y la cantidad de falsos positivos en umbrales de detección del 35 % y 55 % en 27 y 56 espacios, seleccionaron YOLO v5 como la red principal para la detección de automóviles, obteniendo

un promedio de error en detecciones del 5.33 %. Para el conteo de vehículos, aplicaron sistemas de limitación por líneas y región de interés, optando por la selección por región de interés delimitando las secciones a contabilizar mediante procesamiento de imágenes, debido a la morfología de los estacionamientos y la menor tasa de error en las detecciones de espacios. Finalmente, desarrollaron una interfaz gráfica de usuario para ambas redes, con funcionalidades para inicializar la cámara y la red neuronal, visualizar el conteo de espacios de estacionamiento y finalizar la ejecución del sistema de detección y conteo.

Coanqui Apaza et al. (2022) aplicaron dos métodos tecnológicos para automatizar el conteo y clasificación vehicular, tradicionalmente realizado de forma manual: inteligencia artificial con redes neuronales convolucionales y visión artificial mediante librerías virtuales. El objetivo fue comparar la precisión de ambos métodos con un estudio manual in situ (considerado con 100 % de precisión) utilizando una videgrabación real de flujo vehicular con seis clases de vehículos. Los mejores resultados obtenidos fueron un 95.60 % de precisión para el conteo y clasificación de microbuses con inteligencia artificial y un 97.80 % con visión artificial. Los autores concluyeron que la inteligencia artificial es el método más apropiado para automatizar el aforo vehicular, emulando las capacidades humanas, mientras que la visión artificial, aunque más precisa en la prueba específica, es menos confiable en diversas zonas de estudio debido a su dependencia de áreas de detección fijas. Recomendaron entrenar la red neuronal con una base de datos más amplia y utilizar hardware óptimo para mejorar la precisión con inteligencia artificial.

Nizama Yamunaque (2022) desarrolla un sistema de detección, clasificación y conteo vehicular mediante redes neuronales de aprendizaje profundo y visión artificial, buscando optimizar los aforos de tráfico, herramienta crucial para la planificación vial. El autor resalta la necesidad de alternativas accesibles y económicas basadas en inteligencia artificial. Su estudio empleó redes neuronales convolucionales para la detección y clasificación vehicular, inspiradas en el procesamiento visual humano. Tras analizar la precisión y el tiempo de procesamiento de diversas redes neuronales, concluyó que YoloV3 demostró ser particularmente efectiva y precisa para el procesamiento de videos en aforos vehiculares, superando a Detectron2 en términos de calidad de resultados y eficiencia temporal.

Montoya Calderón (2021) aborda el problema de la congestión vehicular en Lima Metropolitana, señalando que una de las causas principales es el sistema de semaforización, donde un alto porcentaje de semáforos no están interconectados y operan con tiempos preestablecidos. El autor propone como solución un controlador descentralizado adaptable para optimizar los tiempos de los ciclos semafóricos en tiempo real, basado en un modelo edge computing y aprovechando la infraestructura existente en las intersecciones. El diseño del controlador incluye un algoritmo de control basado en una política de asignación proporcional generalizada, cuya eficacia se evaluará mediante simulación comparándola con el sistema actual.

2.2. Bases teóricas

2.2.1. Congestión vehicular

2.2.1.1 Definición del transporte

El transporte se refiere al sistema que permite el movimiento de personas, bienes o mercancías de un lugar a otro utilizando diferentes medios o modos (terrestre, acuático, aéreo). Es un concepto amplio que incluye la infraestructura, vehículos y operaciones necesarias para este desplazamiento.

Según Cal y Mayor Reyes Spíndola y Cárdenas Grisales (2018), “El transporte constituye una actividad fundamental en la sociedad que permite la movilización de personas y bienes para satisfacer necesidades básicas como trabajo, educación, recreación y comercio, siendo un factor determinante en el desarrollo económico y social de las regiones”.

2.2.1.2 Definición del tráfico

El tráfico hace referencia al flujo o circulación de vehículos por una vía específica. Se centra en el volumen, composición y comportamiento de los vehículos que utilizan una infraestructura determinada.

Garber y Hoel (2020) establecen que el tráfico se define como el fenómeno generado por el desplazamiento de vehículos a través de una infraestructura vial específica, caracterizado por parámetros fundamentales como el flujo, la densidad y la velocidad. Este desplazamiento vehicular constituye la unidad básica de análisis en la ingeniería de tránsito, permitiendo cuantificar la demanda de transporte y evaluar el comportamiento operacional de las vías.



Figura 2: Tráfico vehicular en el Jirón Carlos F. Vivanco-Ayacucho

Fuente: Imagen propia

2.2.1.3 Definición del tránsito

El tránsito se relaciona con la acción de transitar o circular, abarcando todos los usuarios de las vías (peatones, ciclistas, conductores de vehículos) y las reglas que organizan y regulan esta circulación.

Roess et al. (2019) definen el tránsito como el movimiento ordenado de personas y vehículos por las diferentes vías de circulación, sujeto a un conjunto de normas y regulaciones que organizan y controlan dicho desplazamiento. El tránsito incluye no solo el movimiento vehicular sino también el peatonal, constituyendo un sistema complejo donde interactúan múltiples usuarios con diferentes características y necesidades.

2.2.1.4 Definición de la congestión vehicular

Condición de flujo vehicular que se presenta cuando la demanda de tránsito excede la capacidad de la infraestructura vial disponible, caracterizada por la reducción de velocidades de circulación, incremento en los tiempos de viaje y formación de colas. Este fenómeno representa un desequilibrio entre la oferta y demanda de espacio vial que deteriora la movilidad urbana, aumenta los costos operacionales de los vehículos, incrementa los niveles de contaminación ambiental y acústica Bull (2003).

2.2.1.5 Congestionamiento vehicular en centros históricos

La congestión vehicular en centros históricos, constituye un fenómeno crítico caracterizado por la incompatibilidad estructural entre el trazado urbano de valor patrimonial y las demandas de movilidad contemporánea. Estos espacios, diseñados originalmente para flujos peatonales o de transporte no motorizado, presentan calles estrechas, intersecciones irregulares y geometrías viales inadecuadas para los volúmenes vehiculares actuales. La saturación resultante no solo deteriora la funcionalidad del sistema de transporte, manifestándose en demoras excesivas y operación inestable, sino que además compromete la integridad del patrimonio arquitectónico y la calidad ambiental de estos entornos urbanos de valor histórico Cordero (2012).




Figura 3: Congestionamiento vehicular en el centro histórico de Ayacucho
Fuente: Imagen propia

2.2.1.6 Métricas de congestión vehicular

1. Nivel de servicio

El Nivel de servicio es una medida cualitativa que describe las condiciones operativas dentro de un flujo de tráfico y la percepción de los conductores y/o pasajeros. Según Highway Capacity Manual (HCM, 2016), el Highway Capacity Manual (HCM) establece seis niveles identificados con las letras A a F.

- **Nivel A:** Representa condiciones de flujo libre con excelente nivel de comodidad físico y psicológico para los conductores. Los vehículos prácticamente no se ven afectados por la presencia de otros en la corriente de tránsito.
- **Nivel B:** Flujo estable con ligeras restricciones, la capacidad de maniobra dentro de la corriente de tránsito sólo se ve ligeramente restringida y el nivel de comodidad física y psicológica proporcionado a los conductores es alto.
- **Nivel C:** Flujo estable pero la libertad de maniobra comienza a estar más restringida. Marca el inicio del rango de flujo en el que la operación de los usuarios individuales se ve afectada de forma significativa por las interacciones con otros usuarios.
- **Nivel D:** Flujo próximo a inestable con alta densidad. La capacidad de maniobra está severamente restringida y el nivel de comodidad física y psicológica experimentado por los conductores es deficiente.
- **Nivel E:** Flujo inestable, operación a capacidad. Las operaciones en este nivel son volátiles porque virtualmente no existen intervalos utilizables en la corriente de tránsito.
- **Nivel F:** Flujo forzado o en colapso. Representa condiciones de flujo forzado. Esta condición existe donde la cantidad de vehículos que llegan a un punto excede la cantidad de vehículos que pueden pasar por él.

2. Índice de congestión

El índice de congestión vehicular (ICV) es una medida de la saturación relativa de una vía. Se define mediante la relación:

$$ICV = \frac{V}{C} \quad (1)$$

Donde:

- V = Volumen de tráfico (veh/h).
- C = Capacidad de la vía (veh/h).

Esta relación puede interpretarse de la siguiente manera:

- **ICV < 0.60:** Flujo libre, sin congestión.
- **0.60 ≤ ICV < 0.75:** Flujo estable con mínima influencia entre vehículos.
- **0.75 ≤ ICV < 0.85:** Flujo aún estable pero con restricciones para el cambio de carril.
- **0.85 ≤ ICV < 0.95:** Flujo cercano a la inestabilidad, alta sensibilidad a incidentes.
- **0.95 ≤ ICV < 1.00:** Flujo al límite de la capacidad, muy inestable.
- **ICV ≥ 1.00:** Demanda supera la capacidad, formación de colas.

3. Densidad Vehicular

La densidad vehicular es una medida fundamental que relaciona el número de vehículos y el espacio que ocupan en la vía. Se define como:

$$k = \frac{N}{L} \quad (2)$$

Donde:

- k = Densidad (vehículos/km).
- N = Número de vehículos en el tramo.
- L = Longitud del tramo (km).

De acuerdo con HCM (2016), los rangos de densidad se correlacionan con los niveles de servicio de la siguiente manera para autopistas:

- **Nivel A:** 0-7 veh/km/carril.
- **Nivel B:** 7-11 veh/km/carril.
- **Nivel C:** 11-16 veh/km/carril.
- **Nivel D:** 16-22 veh/km/carril.
- **Nivel E:** 22-28 veh/km/carril.
- **Nivel F:** >28 veh/km/carril.

La densidad vehicular es especialmente útil para analizar condiciones congestionadas, ya que tiene una relación directa con el espaciamiento entre vehículos, un factor determinante en la seguridad vial.

4. Velocidad media de recorrido

La velocidad media de recorrido es un indicador esencial para evaluar la calidad del flujo vehicular. Se puede utilizar para calcular el Índice de retardo por congestión (IRC):

$$IRC = \frac{V_r}{V_f} \quad (3)$$

Donde:

- IRC = Índice de retardo por congestión.
- V_r = Velocidad real (km/h).
- V_f = Velocidad de flujo libre (km/h).

Donde:

- **IRC > 0.85:** Condiciones de flujo libre.
- **0.70 ≤ IRC ≤ 0.85:** Congestión ligera.
- **0.60 ≤ IRC < 0.70:** Congestión moderada.
- **0.35 ≤ IRC < 0.60:** Congestión severa.
- **IRC < 0.35:** Congestión extrema.

5. Tiempos de demora

Según Akçelik y Besley (2001), el tiempo de demora es un parámetro crucial en intersecciones semaforizadas. El modelo propuesto descompone la demora total como:

$$d = d_1 + d_2 \quad (4)$$

Donde:

- d = Demora total (s/veh).
- d_1 = Demora uniforme (debido al ciclo semafórico) (s/veh).
- d_2 = Demora incremental (debido a la saturación) (s/veh).

La demora uniforme se calcula como:

$$d_1 = \frac{0,5 \times C \times (1 - g/C)^2}{1 - [\text{mín}(1, X) \times g/C]} \quad (5)$$

Donde:

- C = Tiempo de ciclo (s).
- g = Tiempo de verde efectivo (s).
- X = Grado de saturación (V/C).

La demora incremental se calcula con el modelo actualizado:

$$d_2 = 900 \times T \times \left[(X - 1) + \sqrt{(X - 1)^2 + \frac{8 \times k \times I \times X}{c \times T}} \right] \quad (6)$$

Donde:

- T = Duración del período de análisis (h).
- k = Factor de ajuste por tipo de controlador.
- I = Factor de ajuste por infiltración aguas arriba.
- c = Capacidad del grupo de carriles (veh/h).

De acuerdo con HCM (2016), relaciona los tiempos de demora con los niveles de servicio en intersecciones semaforizadas:

- **Nivel A:** ≤ 10 s/veh.
- **Nivel B:** $> 10 - 20$ s/veh.
- **Nivel C:** $> 20 - 35$ s/veh.
- **Nivel D:** $> 35 - 55$ s/veh.
- **Nivel E:** $> 55 - 80$ s/veh.
- **Nivel F:** > 80 s/veh.

6. Unidad de coche patron (UCP)

El UCP (Unidad de coche patron) en el contexto del tráfico se refiere al componente central computacional que forma parte de los sistemas inteligentes de transporte. Este elemento tecnológico es responsable de la gestión y coordinación centralizada del tráfico vehicular en entornos urbanos.

El UCP, es una métrica estandarizada en ingeniería de transporte que asigna valores relativos a diferentes tipos de vehículos según su impacto en el flujo del tráfico, tomando como referencia un automóvil particular (valor 1.0). Esta herramienta permite homogeneizar el análisis del tráfico al convertir diversos vehículos (motocicletas, camiones, autobuses) a una unidad común, considerando factores como la superficie que ocupan, sus características dinámicas y su impacto en la capacidad vial. El UCP facilita el cálculo preciso de la capacidad de las infraestructuras, la modelización del comportamiento del tráfico y la toma de decisiones en planificación urbana, posibilitando comparaciones más precisas entre diferentes configuraciones de vías y composiciones de tráfico Abbas et al. (2023).

El UCP realiza cinco funciones fundamentales en los sistemas modernos de tráfico:

- **Adquisición de datos:** Recopilación en tiempo real de información sobre volumen de tráfico, velocidad media, densidad vehicular y condiciones ambientales.
- **Procesamiento y análisis:** Interpretación de los datos recopilados mediante algoritmos específicos para identificar patrones, predecir congestiones y determinar estrategias de gestión.
- **Control adaptativo:** Ajuste dinámico de la señalización y elementos de control vial para responder a las condiciones cambiantes del tráfico.
- **Coordinación multimodal:** Integración de diferentes modos de transporte para optimizar la movilidad urbana en su conjunto.
- **Comunicación con sistemas periféricos:** Intercambio de información con otros componentes del sistema integral de transporte.

7. Grado de saturación

El grado de saturación es una medida fundamental para evaluar intersecciones semaforizadas. Se define como:

$$GS = \frac{q \times c}{s \times g} \quad (7)$$

Donde:

- GS = Grado de saturación.
- q = Flujo vehicular (veh/h).
- c = Tiempo de ciclo semafórico (s).
- s = Flujo de saturación (veh/h).
- g = Tiempo de verde efectivo (s).

Los rangos de interpretación son:

- **$GS < 0.85$:** La intersección opera bajo capacidad con reserva suficiente.
- **$0.85 \leq GS < 0.95$:** La intersección opera cerca de su capacidad, con poca reserva.
- **$0.95 \leq GS < 1.00$:** La intersección opera prácticamente a capacidad.
- **$GS \geq 1.00$:** La demanda excede la capacidad, generando colas crecientes.

2.3. Marco conceptual

2.3.1. Modelo de tráfico vehicular

2.3.1.1 Modelos tradicionales de gestión de tráfico

1. Modelos macroscópicos

Los modelos macroscópicos representan el flujo vehicular como un continuo fluido, centrándose en las propiedades agregadas del tráfico sin considerar vehículos individuales. Los modelos macroscópicos describen el tráfico mediante variables agregadas como densidad (k), flujo (q) y velocidad (v), tratando el flujo vehicular como un fluido continuo regido por ecuaciones diferenciales derivadas de la conservación de masa. Estos modelos se fundamentan en la relación fundamental del tráfico $q = k \cdot v$ y se caracterizan por su capacidad para simular redes extensas con requisitos computacionales moderados, su principal limitación es la incapacidad para representar interacciones individuales entre vehículos o comportamientos específicos de conductores, lo que reduce su precisión en escenarios donde estas dinámicas microscópicas son determinantes Papageorgiou y Messmer (1991).

Los modelos macroscópicos representan el flujo vehicular de manera genérica, se consideran la velocidad espacial al flujo y la densidad del tráfico. Se utilizan usualmente para analizar la eficiencia en corto tiempo Arrieta (2013).




Figura 4: Relación entre flujo y densidad en un modelo macroscópico
Fuente: Imagen propia.

2. Modelos microscópicos

Los modelos microscópicos se enfocan en el comportamiento individual de cada vehículo, modelando interacciones detalladas entre vehículos y su entorno, simulan la dinámica del tráfico a nivel individual, donde cada vehículo se representa como una entidad discreta con características específicas y comportamientos modelados mediante algoritmos determinísticos o estocásticos. Estos modelos contemplan tres submodelos principales: Seguimiento vehicular, cambio de carril y selección de ruta.

El modelo microscópico ofrece una representación detallada de la dinámica de cada vehículo y del comportamiento peatonal. En consecuencia, posibilita el cálculo de la dinámica del tráfico a partir de modelos individuales de vehículos, los cuales se fundamentan en sus interacciones y movimientos particulares Zhang y Su (2021).

Los modelos de microsimulación de tráfico demuestran una importancia fundamental para garantizar la sostenibilidad y la accesibilidad del transporte público. Estas herramientas analíticas posibilitan el estudio del flujo tanto de pasajeros como de vehículos en puntos específicos de tránsito, considerando diversas situaciones de demanda de tráfico. Los resultados derivados de estos análisis son esenciales para la toma de decisiones fundamentadas en relación con el diseño y la optimización de las infraestructuras de transporte, asegurando así un sistema que sea eficiente y sostenible a largo plazo Krivda et al. (2021).




Figura 5: Simulación microscópica del tráfico
Fuente: Imagen propia

3. Modelos mesoscópicos

Los modelos mesoscópicos están compuestos por características de los modelos microscópicos y los macroscópicos, por tanto, se encuentran en el intermedio de ambos modelos, y abarcan principalmente el comportamiento de los conductores en tiempo y espacio en un sistema de tráfico Jiménez (2011).

Los modelos mesoscópicos combinan características de los enfoques macroscópicos y microscópicos, ofreciendo un equilibrio entre detalle y eficiencia. En estos modelos, los vehículos se agrupan en paquetes o pelotones que comparten características similares, pero mantienen su identidad individual. Las interacciones se modelan mediante funciones probabilísticas basadas en la teoría cinética de gases, donde las decisiones de aceleración, desaceleración y cambio de carril se determinan por la densidad local y las condiciones de tráfico circundantes. Esta aproximación permite simular redes de tamaño considerable con un nivel de detalle suficiente para capturar fenómenos emergentes, manteniendo una eficiencia computacional superior a los modelos microscópicos puros Hoogendoorn y Bovy (2001).




Figura 6: Modelo mesoscópico: Pelotones de vehículos
Fuente: Imagen propia

Cuadro 1: Comparativa de modelos de simulación de tráfico

Característica	Macroscópico	Microscópico	Mesoscópico
Variables clave	Densidad, flujo, velocidad	Aceleración, brecha, velocidad individual	Distribuciones de velocidad, densidad local
Escala de aplicación	Redes extensas	Intersecciones, segmentos cortos	Redes de tamaño medio
Precisión	Baja a media	Alta	Media
Costo computacional	Bajo	Alto	Medio
Software típico	VISUM, EMME	VISSIM, AIMSUN, SUMO	DYNAMIT, CONTRAM
Fenómenos capturados	Ondas de choque, flujo máximo	Interacciones individuales, comportamiento stop-and-go	Formación de pelotones, variaciones en tiempos de viaje

Fuente: Elaboración propia

2.3.1.2 Modelo de tráfico vehicular mediante visión artificial

Un modelo de tráfico vehicular, constituye un paradigma avanzado en la gestión del tráfico urbano sobre todo si integra técnicas de visión artificial basadas en redes neuronales convolucionales profundas con sistemas de inferencia espacio-temporal Y. Wang et al. (2022).

Este enfoque permite la identificación, clasificación y seguimiento de múltiples vehículos simultáneamente a través de secuencias de video, generando matrices origen-destino dinámicas que facilitan la predicción de comportamientos y patrones de tráfico en tiempo real.

La visión artificial, busca desarrollar técnicas para que los ordenadores puedan comprender e interpretar imágenes y videos del mundo real. Esta área de la inteligencia artificial tiene como objetivo dotar a las máquinas de la capacidad de extraer información útil a partir de imágenes, emulando en cierta medida la percepción visual humana Szeliski (2022).



Figura 7: Visión artificial
Fuente: Imagen obtenida en la web

2.3.1.3 Machine Learning y Deep Learning

1. Introducción al Machine Learning

El Machine Learning (ML) o aprendizaje automático es una rama de la inteligencia artificial que proporciona a los sistemas la capacidad de aprender y mejorar automáticamente a partir de la experiencia sin ser programados explícitamente. Según Géron (2019), el ML se centra en el desarrollo de algoritmos que pueden acceder a datos y utilizarlos para aprender por sí mismos.

las máquinas tienen la capacidad de aprender por sí solas y auto programarse aprendiendo de su propia experiencia, mejorando su rendimiento en función a los resultados anteriores de manera automática Lasse (2018).

2. Tipos de aprendizaje en Machine Learning

Según Lasse (2018) ,existen diferentes formas de llevar a cabo el aprendizaje automático de las redes neuronales, estas se pueden clasificar en: aprendizaje supervisado, no supervisado y de refuerzo.

- **Aprendizaje Supervisado:** El algoritmo aprende a partir de datos etiquetados, estableciendo una correspondencia entre entradas y salidas deseadas. Las tareas típicas incluyen clasificación y regresión.
- **Aprendizaje No Supervisado:** El algoritmo trabaja con datos no etiquetados, identificando patrones y estructuras inherentes. Las tareas comunes incluyen agrupamiento (clustering), reducción de dimensionalidad y detección de anomalías.
- **Aprendizaje por Refuerzo:** El algoritmo aprende interactuando con un entorno dinámico, recibiendo retroalimentación en forma de recompensas o penalizaciones según sus acciones.




Figura 8: Diagrama de flujo de aprendizaje supervisado
Fuente: Imagen propia adaptado de Luna Gonzalez (2018)




Figura 9: Diagrama de flujo de aprendizaje no supervisado
Fuente: Imagen propia adaptado de Luna Gonzalez (2018)

3. Deep Learning-Fundamentos

El Deep Learning (DL) o aprendizaje profundo es un subconjunto del Machine Learning que utiliza redes neuronales artificiales con múltiples capas (de ahí el término "profundo") para extraer características y representaciones de alto nivel a partir de datos complejos Goodfellow et al. (2016).

A menudo, los términos inteligencia artificial, Aprendizaje Automático (Machine Learning), Redes Neuronales y aprendizaje profundo (Deep Learning) se emplean de manera intercambiable, pese a que cada uno cumple una función esencial dentro del siguiente. Una manera sencilla de comprender su relación y distinguirlos es mediante la analogía de una matrioshka o muñeca rusa, donde cada término representa fundamentalmente un componente del anterior. De esta forma, el campo de la inteligencia artificial abarca el subcampo del aprendizaje automático, y este último, a su vez, incluye el subcampo del aprendizaje profundo, que utiliza un tipo específico de redes neuronales como la estructura principal de sus algoritmos IBM Cloud Education (2020).




Figura 10: Analogía de una matrioshka respecto a la inteligencia artificial
Fuente: Adaptado de IBM Cloud Education (2020)

4. Ventajas del Deep Learning

- **Aprendizaje de características automático:** Elimina la necesidad de extracción manual de características, aprendiendo representaciones jerárquicas directamente de los datos.
- **Escalabilidad:** Su rendimiento mejora con mayores cantidades de datos y potencia computacional, a diferencia de otros algoritmos que alcanzan una meseta.
- **Transferibilidad:** Los modelos entrenados en una tarea pueden adaptarse eficientemente a otras tareas relacionadas mediante transfer learning.
- **Flexibilidad:** Puede aplicarse a diversos tipos de datos (imágenes, texto, audio, series temporales) con arquitecturas adaptadas.

2.3.1.4 Redes neuronales artificiales (RNA)

1. Definición y analogía biológica

La intrincada y sorprendente estructura del cerebro humano, con sus miles de millones de neuronas interconectadas, posee la capacidad de transmitir información entre sus diversas células nerviosas mediante el proceso de sinapsis. Las neuronas biológicas se componen de tres elementos principales: el cuerpo celular, las dendritas, que funcionan como vías de recepción de señales, y el axón, que actúa como canal de transmisión de información. La sinapsis tiene lugar en la zona de contacto entre una dendrita y el axón de otra neurona. Cuando se presenta un estímulo, ya sea eléctrico o de otro tipo, en estas conexiones se generan intercambios de sustancias, reacciones químicas y la liberación de neurotransmisores. Estas sustancias químicas, según su naturaleza, tienen la capacidad de estimular o inhibir las células receptoras Becerra (2014).

La analogía biológica, se basa en:

- Las neuronas artificiales simulan las neuronas biológicas.
- Las conexiones ponderadas representan las sinapsis.
- La función de activación modela el potencial de acción neuronal.
- La arquitectura en capas refleja la organización de diferentes regiones cerebrales.

2. La neurona artificial

Las redes neuronales artificiales son modelos computacionales inspirados en la estructura y funcionamiento del cerebro humano, compuestos por capas de neuronas interconectadas. Las redes neuronales artificiales se utilizan para procesar información, identificar patrones complejos en los datos y realizar predicciones, se desarrollaron como inspiración el funcionamiento y la conducta de las redes neuronales biológicas. Las RNA se estructuran en capas y poseen la habilidad de identificar relaciones y patrones intrincados, para luego aproximarlos a funciones matemáticas y realizar predicciones de resultados. Vector ITC (2018).

- **Entradas:** Valores numéricos provenientes de los datos o de otras neuronas.
- **Pesos:** Valores que determinan la importancia relativa de cada entrada.
- **Función de agregación:** Generalmente una suma ponderada de las entradas y sus pesos correspondientes.
- **Bias o sesgo:** Un término adicional que permite ajustar el umbral de activación.
- **Función de activación:** Transforma la salida de la función de agregación, introduciendo no-linealidad en el modelo.

Matemáticamente, la salida de una neurona puede expresarse como:

$$y = f \left(\sum_{i=1}^n w_i x_i + b \right) \quad (8)$$

Donde:

- x_i son las entradas.
- w_i son los pesos.
- b es el bias.
- f es la función de activación.




Figura 11: Modelo matemático de una neurona artificial
Fuente: Elaboración propia

3. Funciones de activación Las funciones de activación son componentes cruciales que determinan si una neurona debe activarse, introduciendo no-linealidades esenciales en el sistema. Las funciones de activación más comunes incluyen:

- **Sigmoide:** $f(x) = \frac{1}{1+e^{-x}}$. Transforma valores en el rango $[0,1]$.
- **Tanh:** $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$. Transforma valores en el rango $[-1,1]$.
- **ReLU (Rectified Linear Unit):** $f(x) = \max(0, x)$. Anula valores negativos; ha demostrado acelerar la convergencia.
- **Leaky ReLU:** $f(x) = \max(\alpha x, x)$ donde α es pequeño. Permite un pequeño gradiente para valores negativos.
- **ELU (Exponential Linear Unit):** Combina las ventajas de ReLU mientras mitiga el problema de "neuronas muertas".
- **Softmax:** Utilizada en la capa de salida para problemas de clasificación multiclase, convierte un vector de valores en una distribución de probabilidad.

4. Proceso de Aprendizaje: Propagación hacia adelante y hacia atrás

El entrenamiento de redes neuronales involucra dos procesos fundamentales, según describen Chollet y Allaire (2018):

- **Propagación hacia adelante (Forward Propagation):**
 - Las entradas se alimentan a la red y se propagan a través de todas las capas.
 - Cada neurona aplica su función de transformación.
 - Se obtiene una predicción en la capa de salida.
- **Retropropagación (Backpropagation):**
 - Se calcula el error entre la predicción y el valor real.
 - Este error se propaga hacia atrás a través de la red.
 - Los pesos se ajustan proporcionalmente a su contribución al error.
 - Se utiliza el descenso del gradiente para minimizar la función de pérdida.

2.3.1.5 Tipos de redes neuronales

Existen diversos tipos de arquitecturas de redes neuronales, cada una diseñada para abordar problemas específicos. A continuación se presentan las más relevantes:

1. Redes Neuronales Feedforward (FFNN)

Las redes feedforward o prealimentadas son el tipo más básico de arquitectura, donde la información fluye en una sola dirección, desde la entrada hacia la salida, sin ciclos ni retroalimentación. Según Da Silva et al. (2017), estas redes consisten en:

- Una capa de entrada que recibe los datos.
- Una o más capas ocultas que procesan la información.
- Una capa de salida que produce el resultado final.

2. Redes Neuronales Convolucionales (CNN)

Estas arquitecturas de red se concibieron para emular el funcionamiento de las neuronas presentes en la corteza visual del cerebro, otorgando a las computadoras la capacidad de "ver". Esta característica las ha posicionado como una de las técnicas más utilizadas en el ámbito del Aprendizaje Automático para abordar problemas de visión artificial, mediante el reconocimiento de objetos tanto en imágenes como en videos Núñez (2016).

Las CNN representan una clase de red que opera bajo un paradigma de aprendizaje supervisado y que incorpora múltiples capas ocultas, organizadas de forma jerárquica y especializadas en tareas específicas. A modo ilustrativo, las capas iniciales pueden identificar elementos básicos como líneas, curvas y formas, mientras que, a medida que se avanza hacia capas más profundas, estas se especializan en el reconocimiento de patrones mucho más complejos, tales como rostros humanos, vehículos, animales y objetos diversos.

Una CNN típica incluye:

- **Capas convolucionales:** Aplican filtros (kernels) sobre la entrada para extraer características.
- **Funciones de activación:** Generalmente ReLU, que introduce no-linealidad.
- **Capas de pooling:** Reducen la dimensionalidad espacial (submuestreo), preservando la información más relevante.
- **Capas completamente conectadas:** Realizan la clasificación basada en las características extraídas.




Figura 12: Arquitectura de una CNN
Fuente: Adaptado de Abbas et al. (2023)

3. Redes Neuronales Recurrentes (RNN)

Las Redes Neuronales Recurrentes están especializadas en procesar datos secuenciales, como series temporales o texto. Según Yu et al. (2019), las RNN incluyen conexiones recurrentes que permiten que la información persista, creando una especie de memoria que captura dependencias temporales.

4. Redes neuronales Autoencoders

Los autoencoders son redes neuronales diseñadas para aprender representaciones comprimidas (codificaciones) de datos. Bank et al. (2021) describen su arquitectura:

- Un codificador que comprime los datos de entrada.
- Un cuello de botella que contiene la representación de dimensión reducida.
- Un decodificador que reconstruye los datos originales.

5. Redes Generativas Adversarias (GAN)

Introducidas por Goodfellow et al. (2016), las GAN consisten en dos redes que compiten entre sí:

- El generador que crea muestras sintéticas.
- El discriminador que intenta distinguir entre muestras reales y generadas.

Esta competencia adversarial lleva al generador a producir datos indistinguibles de los reales, las GAN han revolucionado la generación de imágenes, video, música y otros tipos de contenido.

6. Redes neuronales Transformers

Los Transformers, introducidos por Vaswani et al. (2017), representan una arquitectura revolucionaria basada en mecanismos de atención que ha superado a las RNN en tareas de procesamiento de lenguaje natural y recientemente en visión por computador.

Las características clave de los transformers incluyen:

- Mecanismos de auto-atención que permiten modelar dependencias globales.
- Procesamiento paralelo que acelera significativamente el entrenamiento.
- Arquitectura codificador-decodificador para tareas de secuencia a secuencia.

2.3.1.6 Profundización en las Redes Neuronales Convolucionales (CNN):

Funcionamiento de las CNN

Las CNN toman una entrada, que en este caso es una imagen. Esta imagen puede representarse como una matriz multidimensional y se somete a una transformación mediante una secuencia de filtros, también conocidos como kernels. Una imagen posee un ancho (correspondiente al número de columnas) y una altura (equivalente al número de filas), al igual que una matriz. Sin embargo, a diferencia de las matrices convencionales, las imágenes tienen una dimensión adicional denominada profundidad, que está determinada por sus canales de color y contiene los valores numéricos de sus píxeles. Por ejemplo, una imagen a color en formato RGB (rojo, verde, azul) presenta una profundidad de tres canales, uno para cada color primario, mientras que una imagen en escala de grises tiene una profundidad de un solo canal. Los valores de los píxeles en estas imágenes suelen oscilar entre 0 y 255, y para optimizar el procesamiento, es preferible convertirlos a un rango entre 0 y 1, lo cual se logra dividiendo el valor de cada píxel por 255 Nizama Yamunaque (2022).

A. Operación de convolución y Kernels

Una convolución implica la agregación de los elementos de una matriz producto, obtenida al multiplicar término a término dos matrices: Una que representa una sección de la imagen de entrada y otra que corresponde a un kernel. Un kernel, o filtro, puede definirse como una matriz de dimensiones reducidas (en relación con la matriz que representa la imagen) y se emplea para diversas operaciones como enfocar, desenfocar, suavizar, o identificar características como líneas, formas y bordes. Este kernel se desplaza secuencialmente, píxel

a píxel, sobre todas las neuronas de la capa de entrada, desde la izquierda hacia la derecha y de arriba hacia abajo, generando una nueva matriz de salida, la cual constituye una nueva capa oculta de neuronas.

La operación de convolución es el componente fundamental de las CNN. Según Yamashita et al. (2018), esta operación consiste en:

- Un kernel (o filtro) que se desliza sobre la imagen de entrada.
- Para cada posición, se calcula el producto escalar entre el kernel y la región correspondiente de la entrada.
- El resultado forma un mapa de características que resalta patrones específicos

Matemáticamente, para una imagen 2D, la convolución discreta se expresa como:

$$(I * K)(i, j) = \sum_m \sum_n I(i + m, j + n) \cdot K(m, n) \quad (9)$$

Donde:

- I es la imagen de entrada.
- K es el kernel o filtro.
- $*$ denota la operación de convolución.

Diferentes kernels detectan diferentes características:

- Kernels de bordes detectan transiciones en la intensidad.
- Kernels de textura identifican patrones repetitivos.
- Kernels de blur suavizan detalles.
- **Inicialización de kernels:** Los kernels se inicializan aleatoriamente y se ajustan durante el entrenamiento.
- **Aplicación del kernel:** El kernel se desliza sobre la entrada, calculando el producto escalar en cada posición.
- **Formación del mapa de características:** Los resultados se organizan en un nuevo tensor llamado mapa de características.
- **Aplicación de bias y activación:** Se añade un término de sesgo y se aplica una función de activación.

B. Comprensión de las convoluciones

La figura N° 13 ilustra un ejemplo de convolución aplicada a una imagen de 6x6 (compuesta por 36 neuronas) utilizando un kernel de 3x3. En cada paso, el centro del kernel se alinea con la coordenada (x,y) del elemento a filtrar en la imagen de entrada. Luego, se multiplican los valores de los elementos de la región de la imagen que se superpone con el kernel, y se suman estos productos. El resultado de esta suma se coloca en la misma coordenada (x,y) en la matriz de salida. La figura N° 14 despliega el proceso completo de aplicar convoluciones a una imagen de entrada de 6x6. En este caso, se realizaron 16 convoluciones utilizando el mismo kernel de 3x3, lo que generó una matriz de salida de 4x4 (con 16 neuronas). Este proceso se inicia en la esquina superior izquierda de la imagen y avanza secuencialmente de izquierda a derecha y de arriba a abajo. La aplicación de un kernel

a una imagen de entrada produce una matriz de salida que contiene información filtrada de la imagen original, resaltando patrones que contribuyen al reconocimiento de formas u objetos. Para preservar las dimensiones de la matriz de salida, igualándolas a las de la entrada, se suele recurrir a la técnica de agregar píxeles con valor cero en los bordes de la imagen de salida. Nizama Yamunaque (2022).

131	162	232	84	91	207
104	93	139	101	237	109
243	26	252	196	135	126
185	135	230	48	61	225
157	124	25	14	102	108
5	155	116	218	232	249

★

-1	0	1
-2	0	2
-1	0	1

Figura 13: Convolución con un kernel de 3x3
Fuente: Elaboración propia

Operación de convolución a partir de la figura:

$$\begin{aligned}
 \text{mmmC} &= \sum_{a_{11}}^{a_{ij}} \left[\begin{bmatrix} 93 & 139 & 101 \\ 26 & 252 & 196 \\ 135 & 230 & 48 \end{bmatrix} \star \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} \right] \\
 C &= \sum_{a_{11}}^{a_{ij}} \begin{bmatrix} 93 \times (-1) & 139 \times 0 & 101 \times 1 \\ 26 \times (-2) & 252 \times 0 & 196 \times 2 \\ 135 \times (-1) & 230 \times 0 & 48 \times 1 \end{bmatrix} \\
 C &= \sum_{a_{11}}^{a_{ij}} \begin{bmatrix} -93 & 0 & 101 \\ -52 & 0 & 392 \\ -135 & 0 & 48 \end{bmatrix} = 261
 \end{aligned}$$

Matriz de entrada							kernel		Matriz de salida				
131	162	232	84	91	207								
104	93	139	101	237	109								
243	26	252	196	135	126	★							
185	135	230	48	61	225								
157	124	25	14	102	108								
5	155	116	218	232	249								

-1	0	1
-2	0	2
-1	0	1

180	108	-62	69
98	261	-305	45
-33	-114	-378	378
-108	-244	101	396

Figura 14: Convoluciones a una matriz de entrada de 6x6 con un kernel de 3x3
Fuente: Elaboración propia

Un aspecto relevante es que una única imagen puede ser procesada por múltiples kernels (o conjuntos de filtros), lo que genera una colección de matrices resultantes denominadas mapas de características. De esta manera, la aplicación de, por ejemplo, 24 filtros a una misma imagen producirá 24 mapas de características, cada uno conteniendo información filtrada de la imagen original. Esta información filtrada es crucial en las capas más profundas de la red para diferenciar entre diversas clases de objetos, como personas, animales, objetos inanimados, vehículos, entre otros.

C. Función de activación-ReLu

De forma análoga al proceso sináptico en los sistemas biológicos, las Redes Neuronales Artificiales (RNA) incorporan una función de activación que altera el valor de una neurona con el fin de activarla y propagar un resultado a la siguiente conexión, equivalente a la sinapsis. Esta función establece si el valor de una neurona, representado por los valores de la matriz de salida, excede un umbral predefinido para ser transmitido a la capa siguiente. En el contexto de las (CNN), la función de activación que ha demostrado ser más eficaz y arrojar los mejores resultados es la Unidad Lineal Rectificada, conocida como ReLU (Rectified Linear Unit) Ramachandran et al. (2017), se define matemáticamente la función ReLU:

$$f(x) = \max(0, x) = \begin{cases} 0 & , \text{ si } x < 0 \\ x & , \text{ si } x \geq 0 \end{cases} \quad (10)$$

La figura N° 15 ilustra la aplicación de la función de activación ReLU a la matriz de salida presentada en la figura N° 14. La función ReLU opera transformando el valor de cada neurona (o píxel): Si el valor recibido como entrada es negativo, lo convierte a cero; en caso contrario, el valor se mantiene sin modificaciones. En el ejemplo de la figura N° 15, los valores de entrada negativos, fueron reemplazados por cero (0), mientras que los demás valores permanecieron intactos.

180	108	-62	69
98	261	-305	45
-33	-114	-378	378
-108	-244	101	396

$$\xrightarrow{f(x) = \max(0, x)}$$

180	108	0	69
98	261	0	45
0	0	0	378
0	0	101	396

Figura 15: Aplicación de la función de activación ReLU
Fuente: Elaboración propia

D. Pooling- Agrupación

Constituye una estrategia fundamental para disminuir la dimensión espacial de una imagen. Su propósito principal radica en la reducción del número de neuronas (píxeles) y la simplificación de los cálculos previos a una nueva convolución. Este proceso implica la agrupación de varios píxeles en uno solo, reteniendo la información más significativa.

Existen diversas modalidades de pooling, entre las que se encuentran el Max Pooling (que selecciona el valor máximo dentro de una subregión de píxeles), el Min Pooling (que elige el valor mínimo) y el Average Pooling (que calcula el valor promedio). No obstante, el Max Pooling se destaca como una técnica de submuestreo altamente eficaz en las Redes Neuronales Convolucionales (RNC) para condensar las características de una región. Esta operación consiste en identificar el valor máximo dentro de una muestra y utilizar dicho valor como un resumen representativo de las características presentes en esa área. Al aplicar un Max Pooling de 2x2, se logra una reducción del tamaño de la imagen a la mitad.

La figura N° 16 ilustra un ejemplo de la aplicación de un Max Pooling de 2x2 a la matriz de salida obtenida en la Figura N° 15. Para la primera región de 2x2 (señalada en rojo), el valor máximo es 261; para la segunda región (en verde), es 69; para la tercera región (en azul), es 0; y para la cuarta región (en amarillo), es 396. Como resultado de esta operación, la imagen de entrada de 4x4 se reduce a una imagen de 2x2.

180	108	0	69	→	<i>Max Pooling</i>	
98	261	0	45		261	69
0	0	0	378		0	396
0	0	101	396			

Figura 16: Aplicación de un Max Pooling de 2x2
Fuente: Elaboración propia

En conclusión, tras la aplicación de un kernel de 3x3 y un Max Pooling de 2x2 a nuestra imagen de entrada original de 6x6, se obtiene una imagen de salida de 2x2 que encapsula información filtrada y relevante de la imagen inicial. Esta información es crucial para la identificación y el reconocimiento de patrones de formas u objetos. Como se mencionó anteriormente, es posible aplicar múltiples kernels (filtros) a una misma imagen de entrada. Algunos de estos filtros pueden especializarse en la detección de bordes, otros en sombras, otros en curvas, otros en líneas horizontales o verticales, y así sucesivamente, dependiendo de su función específica. La aplicación de múltiples kernels a una imagen generará una cantidad equivalente de matrices de salida (mapas de características), lo que incrementará la profundidad de nuestras capas neuronales.

E. Síntesis del proceso de una CCNN

Una vez comprendido el mecanismo y la operativa de las Redes Neuronales Convolucionales (RNC), se puede establecer que una convolución dentro de una RNC se constituye por una imagen de entrada, un grupo de filtros (kernels), la aplicación de una función de activación y una operación de Max-Pooling. A medida que se efectúan más convoluciones, se generan capas neuronales progresivamente más profundas, con la capacidad de identificar patrones de formas de mayor complejidad. Este proceso iterativo

continúa hasta que la capa final de la red puede clasificar las imágenes detectadas en categorías o grupos específicos, asignándoles una probabilidad de certeza.

El Cuadro N° 2 muestra los resultados de aplicar una secuencia de tres convoluciones a una imagen de 48x48 píxeles en escala de grises (representada como 48x48x1). Para la primera convolución, se emplearon 15 filtros de 3x3; para la segunda, 30 filtros de 3x3; y para la tercera, 45 filtros de 3x3. Adicionalmente, se aplicó una operación de Max Pooling de 2x2 después de cada capa convolucional.

Cuadro 2: Proceso de convoluciones a una imagen de 48x48 píxeles

DESCRIPCIÓN	1era Convolución	2da Convolución	3era Convolución
1) Entrada: Imagen	48x48x1	24x24x15	12x12x30
2) Kernel (filtros)	15 filtros 3x3x1	30 filtros 3x3x15	45 filtros 3x3x30
3) Feature Mapping	48x48x15	24x24x30	12x12x45
4) Func. de Activación	ReLU	ReLU	ReLU
5) Max Pooling	de 2x2	de 2x2	de 2x2
6) Salida: Convolución	24x24x15	12x12x30	6x6x45

Fuente: Elaboración propia

La imagen inicial de 48x48 píxeles en escala de grises (48x48x1) contiene 2,304 unidades de información o neuronas. En el proceso de la primera capa convolucional, se implementaron 15 filtros de tamaño 3x3, generando 15 diferentes mapas de características (48x48x15). Tras aplicar Max Pooling 2x2, estas representaciones se redujeron a dimensiones de 24x24 para cada uno de los 15 mapas, resultando en un total de 8,640 neuronas activas.

Para la segunda etapa convolucional, estos 15 mapas de 24x24 píxeles fueron procesados con 30 filtros de 3x3, creando 30 nuevos mapas de características (24x24x30). Al implementar otro Max Pooling 2x2, el tamaño se redujo a 12x12 píxeles por mapa, condensando la información en 4,320 neuronas. Este paso evidencia una disminución notable del 50 % en la cantidad de unidades procesadas respecto a la etapa anterior.

En la tercera fase, los 30 mapas de 12x12 píxeles fueron tratados con 45 filtros de 3x3, generando 45 mapas de características (12x12x45). El último Max Pooling 2x2 los transformó en representaciones de 6x6 píxeles cada uno (6x6x45), totalizando 1,620 neuronas. Este proceso demuestra cómo la arquitectura convolucional logra comprimir la información original de 2,304 neuronas a 1,620 neuronas finales, conservando únicamente los elementos más distintivos y significativos. Estas neuronas resultantes contienen datos esenciales para la identificación de características específicas (como rasgos faciales o componentes de vehículos) y el reconocimiento de objetos complejos presentes en la imagen original.




Figura 17: CNN típica y sus diferentes capas de procesamiento
Fuente: Elaboración propia

2.3.1.7 Métricas de evaluación CNN

1. Matriz de confusión y métricas derivadas

La matriz de confusión constituye la base para múltiples métricas de evaluación en problemas de clasificación. De acuerdo con Minaee et al. (2021), esta matriz proporciona una visión completa del rendimiento del modelo al mostrar la relación entre las predicciones y las etiquetas reales.

A partir de la matriz de confusión, se derivan las siguientes métricas fundamentales:

2. Exactitud (Accuracy)

La exactitud mide la proporción de predicciones correctas sobre el total de instancias evaluadas. Si bien es ampliamente utilizada, presenta limitaciones significativas en conjuntos de datos desbalanceados Brownlee (2020).

$$\text{Exactitud} = \frac{TP + TN}{TP + TN + FP + FN} \quad (11)$$

Donde:

- TP (Verdaderos Positivos): Instancias positivas correctamente clasificadas.
- TN (Verdaderos Negativos): Instancias negativas correctamente clasificadas.
- FP (Falsos Positivos): Instancias negativas incorrectamente clasificadas como positivas.
- FN (Falsos Negativos): Instancias positivas incorrectamente clasificadas como negativas.

3. Precisión: La precisión cuantifica la proporción de predicciones positivas que son realmente correctas, siendo especialmente relevante en escenarios donde los falsos positivos tienen un alto costo Evidentlyai (2023).

$$\text{Precisión} = \frac{TP}{TP + FP} \quad (12)$$

4. Sensibilidad (Recall): La sensibilidad, también conocida como recall o tasa de verdaderos positivos, mide la capacidad del modelo para identificar correctamente las instancias positivas Google Developers (2023).

$$\text{Sensibilidad} = \frac{TP}{TP + FN} \quad (13)$$

4. Especificidad: La especificidad mide la proporción de negativos reales que son correctamente identificados como tales. Esta métrica es particularmente importante en aplicaciones médicas donde la identificación precisa de casos negativos es crucial Effective Health Care Program (2022).

$$\text{Especificidad} = \frac{TN}{TN + FP} \quad (14)$$

5. F1-Score: El F1-Score representa la media armónica entre precisión y sensibilidad, proporcionando un equilibrio entre ambas métricas. Según The Data Scientist (2023), esta medida es especialmente útil cuando existe un desbalance significativo en las clases.

$$\text{F1-Score} = 2 \times \frac{\text{Precisión} \times \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}} \quad (15)$$

2.3.1.8 Algoritmos de Detección de Objetos

La detección de objetos consiste en identificar la presencia y ubicación de objetos específicos en una imagen, generalmente mediante la predicción de cuadros delimitadores (bounding boxes).

1. Métodos Tradicionales

Los enfoques tradicionales se basan en la extracción manual de características y clasificadores:

- Viola-Jones.
- HOG (Histogram of Oriented Gradients).

2. Métodos basados en aprendizaje profundo

A. Detectores de una etapa

Estos algoritmos predicen directamente las ubicaciones y clases de los objetos en una sola pasada:

- **YOLO-You Only Look Once:** Divide la imagen en una cuadrícula y predice bounding boxes y probabilidades de clase para cada celda.




Figura 18: Representación de la arquitectura Faster R-CNN

Fuente: Adaptado de Abbas et al. (2023)

- **SSD-Single Shot MultiBox Detector:** Utiliza múltiples capas de diferentes escalas para detectar objetos de diversos tamaños.
- **RetinaNet:** Introduce la función de pérdida Focal Loss para abordar el problema del desequilibrio de clases. Eficaz en conjuntos de datos con distribuciones altamente asimétricas.

B. Detectores de dos etapas

Estos modelos primero proponen regiones candidatas y luego clasifican cada región:

- **R-CNN (Region-based CNN)** y sus variantes Fast R-CNN y Faster R-CNN: Utilizan redes de proposición de regiones (RPN) para identificar posibles ubicaciones de objetos. Analizan la evolución de estos modelos y su impacto en la precisión de detección.




Figura 19: Representación de la arquitectura Yolo
Fuente: Adaptado de C. Wang et al. (2025)

- **Mask R-CNN:** Extiende Faster R-CNN para realizar segmentación de instancias simultáneamente. Sumamente versátil en aplicaciones que requieren tanto detección como segmentación precisa.

2.3.1.9 YOLO: You Only Look Once

1. Principios Fundamentales de YOLO

YOLO (You Only Look Once) es un algoritmo revolucionario de detección de objetos en tiempo real desarrollado originalmente por Joseph Redmon et al. en 2015, que a diferencia de los métodos tradicionales de dos etapas, aborda la detección como un problema de regresión directa donde una única red neuronal convolucional procesa la imagen completa en una sola pasada para predecir simultáneamente las cajas delimitadoras y las probabilidades de clase, dividiendo la imagen en una cuadrícula de celdas donde cada celda es responsable de detectar los objetos cuyo centro cae dentro de ella, lo que permite una alta velocidad de procesamiento (45-155 fotogramas por segundo en sus primeras versiones) mientras mantiene una precisión competitiva, características que han convertido a YOLO en uno de los algoritmos más populares para aplicaciones que requieren detección de objetos en tiempo real como vehículos autónomos, videovigilancia y robótica. Redmon et al. (2016)

- **Enfoque de un solo paso:** Realiza detección y clasificación simultáneamente.
- **División en cuadrícula:** Divide la imagen en una cuadrícula $S \times S$.

- **Predicciones por celda:** Cada celda predice B cajas delimitadoras con confianza y probabilidades de clase.
- **Pérdida unificada:** Optimiza conjuntamente localización, confianza y clasificación.

2. Evolución hasta YOLOv8 La arquitectura YOLO ha evolucionado significativamente desde su versión original:

- **YOLOv1-v3:** Desarrolladas por Joseph Redmon, establecieron los fundamentos.
- **YOLOv4-v7:** Impulsadas por Alexey Bochkovskiy y otros, incorporaron avances como CSPNet y transformers.
- **YOLOv8:** Desarrollada por Ultralytics, representa la generación más reciente con importantes mejoras arquitectónicas.

3. Arquitectura y funcionamiento de YOLOv8 YOLOv8, lanzada en 2023, introduce varias innovaciones significativas Jocher et al. (2023) :

- **Backbone mejorado:** Utiliza una arquitectura CSPDarknet más eficiente con bloques residuales avanzados.
- **Neck optimizado:** Implementa PANet (Path Aggregation Network) para mejor fusión multiescala.
- **Cabezas de detección anchorless:** Elimina las anchor boxes predefinidas en favor de predicciones directas.
- **C2f Block:** Nueva unidad de construcción que mejora la eficiencia computacional.
- **Funciones de pérdida avanzadas:** Incorpora DFL (Distribution Focal Loss) y variantes de IoU que mejoran la precisión de localización.

2.3.1.10 Librerías de Yolo para el modelo de tráfico vehicular

La librería Ultralytics YOLO, Matplotlib y Seaborn, Pandas, Collections y Defaultdict, Sklearn, TQDM, representan una implementación moderna del algoritmo, Ultralytics desarrollada específicamente para optimizar el rendimiento y facilitar su uso. Según Jocher (2020), Ultralytics YOLO combina la eficiencia computacional del algoritmo original con mejoras arquitectónicas que han evolucionado a través de las versiones YOLOv3, YOLOv5, YOLOv8 y superiores.

2.3.1.11 LabelMe

LabelMe es una herramienta de anotación de imágenes basada en web desarrollada por el MIT que permite a los usuarios etiquetar objetos en imágenes y compartir esas anotaciones instantáneamente con la comunidad científica, facilitando la creación de bases de datos de imágenes con etiquetas de verdad fundamental para investigación en detección y reconocimiento de objetos, lo que resulta esencial para el aprendizaje supervisado y la evaluación cuantitativa en visión por computadora. El sistema permite extender el conjunto de datos para mejorar automáticamente las etiquetas de objetos con WordNet, descubrir partes de objetos, recuperar el orden de profundidad de los objetos en una escena y aumentar el número de etiquetas

utilizando supervisión mínima del usuario e imágenes de la web. Russell et al. (2008)




Figura 20: Interfaz de LabelMe
Fuente: Elaboración propia

2.3.1.12 Google Colab: Integración con entorno de ejecución

Google Colab (abreviatura de Google Colaboratory) es un servicio de notebooks Jupyter alojado en la nube que no requiere configuración para su uso y proporciona acceso gratuito a recursos computacionales, incluyendo GPUs y TPUs, especialmente diseñado para facilitar la educación e investigación en aprendizaje automático y ciencia de datos. Esta plataforma ofrece un entorno de desarrollo interactivo sin servidor que es particularmente adecuado para el prototipado de modelos de aprendizaje automático, análisis de datos y educación, permitiendo a estudiantes, investigadores y grupos con recursos limitados acceder a hardware potente para ejecutar código Python sin las restricciones típicas de configuración local. SpringerLinkColab Un análisis detallado de su rendimiento ha demostrado que, para aplicaciones de aprendizaje profundo, el desempeño de Colab es equivalente al de estaciones de trabajo dedicadas con recursos similares, lo que lo convierte en una herramienta valiosa para la democratización de la computación avanzada. Bisong (2019).




Figura 21: Ventajas y características de Google Colab
Fuente: Imagen obtenida en la web

2.3.2. Sistemas inteligentes de transporte (ITS)

Los sistemas inteligentes de transporte (ITS, por sus siglas en inglés) representan la integración de tecnologías avanzadas de información y comunicación con la infraestructura de transporte existente. Su objetivo fundamental es mejorar la seguridad, eficiencia y sostenibilidad del sistema de transporte mediante la aplicación de soluciones tecnológicas innovadoras que permiten la recopilación, procesamiento y distribución de información en tiempo real entre vehículos, infraestructura y usuarios. En su base conceptual, los ITS buscan resolver problemas críticos como la congestión vehicular, los accidentes de tránsito y la contaminación ambiental a través de un enfoque sistémico. Este enfoque integra diversas disciplinas, incluyendo la ingeniería de transporte, la electrónica, las telecomunicaciones y la informática, para desarrollar soluciones holísticas que optimicen el rendimiento de las redes de transporte.

2.3.2.1 Tecnologías clave en los ITS

Las tecnologías fundamentales que impulsan los sistemas inteligentes de transporte abarcan una amplia gama de soluciones. Los sistemas de detección y vigilancia, como los sensores de inducción magnética, cámaras de reconocimiento automático de placas (ANPR) y radares de microondas, permiten la recopilación precisa de datos sobre el flujo de tráfico. Estas tecnologías proporcionan información en tiempo real sobre volumen vehicular, velocidad, ocupación y clasificación de vehículos Guerrero-Ibáñez et al. (2018).

El procesamiento avanzado de datos mediante algoritmos de inteligencia artificial y aprendizaje automático constituye otro pilar tecnológico de los ITS modernos. Estos sistemas pueden analizar grandes volúmenes de datos en tiempo real para detectar patrones, predecir condiciones de tráfico, optimizar semáforos adaptativos y facilitar la toma de decisiones basada en evidencia para los gestores de tráfico y los usuarios del sistema de transporte.

2.3.2.2 Sistemas de gestión semafórica inteligente

Un Sistema de Gestión Semafórica Inteligente (SGSI) se define como: Una infraestructura tecnológica integrada que emplea sensores, algoritmos adaptativos y sistemas de comunicación interconectados para optimizar en tiempo real la operación coordinada de múltiples intersecciones semaforizadas. Esta optimización se basa en el análisis continuo de datos de tráfico y condiciones contextuales, permitiendo ajustes automáticos de ciclos, fases y sincronización entre semáforos con el objetivo de maximizar el flujo vehicular, reducir tiempos de espera, disminuir emisiones contaminantes y priorizar, cuando sea necesario, el paso de vehículos de emergencia o transporte público.

Los semáforos constituyen uno de los elementos fundamentales en la gestión del tráfico urbano, regulando el flujo vehicular y peatonal en las intersecciones viales. Su

evolución ha transitado desde sistemas de tiempo fijo hasta complejos algoritmos adaptativos que responden en tiempo real a las condiciones cambiantes del tráfico Koonce et al. (2008).

En el contexto de la movilidad urbana sostenible, los sistemas de control de tráfico modernos buscan optimizar el uso de la infraestructura existente, reducir las demoras, minimizar las emisiones contaminantes y mejorar la seguridad vial.



Figura 22: Representación del sistema de gestión semafórica inteligente

Fuente: Imagen obtenida en la web

2.3.2.3 Semáforos de tiempos dinámicos

Los semáforos de tiempos dinámicos, también denominados semáforos adaptativos o inteligentes, son dispositivos de control de tráfico cuya programación se ajusta automáticamente en respuesta a las variaciones de flujo vehicular, peatonal y otras condiciones del entorno Li et al. (2021). A diferencia de los semáforos de tiempo fijo, estos sistemas pueden modificar parámetros como:

- Duración de las fases (verde, ámbar, rojo).
- Secuencia de fases.
- Ciclo completo del semáforo.
- Coordinación entre intersecciones.

El objetivo principal es adaptar el control semafórico a las necesidades reales del tráfico en cada momento, optimizando así la operación de la red vial .

1.Desarrollo de los semáforos de tiempos dinámicos

El desarrollo de los semáforos de tiempos dinámicos ha pasado por varias etapas significativas:

- **Década de 1960:** Primeros sistemas actuados por vehículos mediante sensores de presión.
- **Década de 1980:** Implementación de sistemas coordinados con capacidad de ajuste por franjas horarias.

- **Década de 1990:** Desarrollo de sistemas adaptativos basados en algoritmos de optimización.
- **Siglo XXI:** Integración de inteligencia artificial, aprendizaje automático y comunicación V2I (vehículo a infraestructura).

2. Componentes del sistema semafórico de tiempos dinámicos

Un sistema semafórico de tiempos dinámicos comprende generalmente los siguientes componentes:

- **Subsistema de detección:** Constituido por sensores que captan la presencia y flujo de vehículos (inductivos, videocámaras, radar, infrarrojos).
- **Unidad de control local:** Procesa la información del subsistema de detección y ejecuta los algoritmos de control.
- **Controlador central:** Coordina múltiples intersecciones y optimiza a nivel de red.
- **Interfaces de comunicación:** Permiten la transmisión de datos entre los distintos componentes.
- **Sistema de monitoreo y supervisión:** Facilita la gestión y evaluación del desempeño.

3. Algoritmos de control semafórico

Los principales enfoques algorítmicos para la operación de semáforos dinámicos incluyen:

- **Algoritmos basados en reglas:** Utilizan un conjunto predefinido de condiciones y acciones que determinan los cambios en los tiempos semafóricos. Su implementación es relativamente sencilla, pero ofrecen una capacidad de adaptación limitada.
- **Algoritmos de optimización** Buscan maximizar o minimizar ciertos parámetros de desempeño como la capacidad, el tiempo de viaje o las demoras. Entre los más destacados se encuentran: SCOOT (Split Cycle Offset Optimization Technique), SCATS (Sydney Coordinated Adaptive Traffic System), OPAC (Optimized Policies for Adaptive Control), RHODES (Real-time Hierarchical Optimized Distributed Effective System).
- **Algoritmos basados en inteligencia artificial:** Incorporan técnicas como redes neuronales, lógica difusa, algoritmos genéticos y aprendizaje por refuerzo para adaptar el control semafórico a patrones complejos de tráfico:
- **Controladores de lógica difusa que modelan la incertidumbre del tráfico:** Redes neuronales que aprenden patrones de comportamiento vehicular Algoritmos de aprendizaje por refuerzo que mejoran su desempeño a medida que operan Técnicas de minería de datos para identificar patrones recurrentes.

4. Tecnologías de sensorización

La efectividad de los semáforos de tiempos dinámicos depende significativamente de la precisión y confiabilidad de los sensores utilizados. Las principales tecnologías incluyen:

- **Lazos inductivos:** Detectan cambios en el campo electromagnético producidos por la presencia de vehículos.
- **Sistemas de visión artificial:** Utilizan cámaras y algoritmos de procesamiento de imágenes para detectar y clasificar vehículos.
- **Radar:** Emplea ondas electromagnéticas para determinar la presencia, velocidad y tipo de vehículos.
- **Detectores acústicos:** Captan y analizan el sonido generado por los vehículos.
- **Sensores infrarrojos:** Detectan la radiación térmica emitida por los vehículos.

5. Comunicación y conectividad entre semáforos dinámicos

Los sistemas modernos de semáforos dinámicos se apoyan en tecnologías de comunicación que permiten:

- Sincronización entre intersecciones (coordinación).
- Comunicación con centros de control de tráfico, interacción con otros componentes de sistemas inteligentes de transporte.
- Conectividad con vehículos (V2I) y peatones.
- Las tecnologías más empleadas incluyen fibra óptica, comunicaciones inalámbricas (5G, DSRC), protocolos TCP/IP.

6. Evaluación de desempeño y beneficios, de los semáforos adaptativos

Para evaluar la efectividad de los semáforos de tiempos dinámicos, se utilizan diversos indicadores:

- Eficiencia operativa: Capacidad, demoras, número de paradas, longitud de colas
- Sostenibilidad ambiental: Consumo de combustible, emisiones contaminantes.
- Seguridad vial: Tasa de accidentes, conflictos potenciales.
- Accesibilidad: Tiempos de viaje, nivel de servicio para peatones y ciclistas
- Costo-beneficio: Relación entre inversión y beneficios obtenido.

Diversos estudios han demostrado los siguientes beneficios de los semáforos de tiempos dinámicos:

- Reducción de tiempos de viaje entre un 8 % y 25 %.
- Disminución de demoras en intersecciones hasta un 40 %.
- Reducción de emisiones contaminantes entre un 5 % y 15 %.
- Mejora de la seguridad vial con reducción de accidentes hasta un 10 %.
- Optimización de la capacidad de la red vial existente.

7. Consideraciones para la implementación

No todas las intersecciones resultan igualmente adecuadas para la implementación de semáforos dinámicos. Los criterios más relevantes para su selección incluyen:

- Variabilidad significativa del flujo vehicular (estacional, diaria, horaria).
- Intersecciones con alta demanda y congestión recurrente.
- Zonas con prioridad para transporte público o vehículos de emergencia.

2.3.2.4 Bases teóricas algoritmos de control semafórico

1. Capacidad vial y flujo de saturación.

La capacidad vial representa uno de los conceptos fundamentales en la ingeniería de tránsito. El Highway Capacity Manual HCM (2016), combina conocimientos teóricos y empíricos para hacer recomendaciones sobre el cálculo de la capacidad de carreteras y la evaluación del nivel de servicio ofrecido a los usuarios.

El HCM (2016) establece como referencia internacional el valor de aproximadamente 1900 UCP/hora/carril (Unidades de Coche Patrón por hora por carril) como capacidad ideal en condiciones óptimas. Este valor teórico máximo para flujo vehicular saturado ha sido ampliamente aceptado y aplicado en el análisis de capacidad vial.

La capacidad ideal requiere ajustes basados en condiciones locales específicas, elementos físicos y geométricos restrictivos como el ancho del carril, la distancia lateral, el alineamiento horizontal de los arcones, gradientes y la condición de la superficie del pavimento son factores que afectan la capacidad y el nivel de servicio. Un ancho de carril de 3.65 m se consideran minimamente ideal para un flujo fluido, mientras que anchos menores pueden reducir la capacidad hasta en un 25 % Engineering Notes (2018).

Esta aproximación ha sido respaldada por estudios de microsimulación desarrollados con herramientas como VISSIM, CORSIM y AIMSUN. Estas herramientas de microsimulación de tráfico permiten análisis detallados de áreas críticas en ubicaciones complejas. Mientras que el HCM utiliza metodologías macroscópicas/mesoscópicas, las herramientas de microsimulación como VISSIM permiten modelar condiciones del mundo real con un alto nivel de precisión y exhaustividad Lu et al. (2014).

Los estudios de calibración de estas herramientas de simulación han confirmado el umbral de aproximadamente 1900 UCP/hora/carril como límite práctico de capacidad bajo condiciones estándar. Federal Highway Administration (2006). La calibración de estos modelos se realiza ajustando parámetros como el factor de seguimiento de vehículos para que el rendimiento del modelo coincida con los valores de capacidad observados en campo.

2. Ciclos semafóricos: Parámetros críticos.

2.1. Tiempo verde mínimos

La implementación de tiempos verdes mínimos se fundamenta en evidencia técnica y estudios de comportamiento:

El *Manual of Traffic Signal Design* (1990) de Ingenieros de Transporte (ITE) establece directrices para los tiempos de cruce peatonal y tiempos verdes mínimos, que son fundamentales para el diseño de intersecciones seguras. Estas directrices buscan garantizar que los peatones puedan cruzar con seguridad y que un número razonable

de vehículos pueda pasar durante cada fase.

Las señales con ciclos cortos ayudan a que las calles urbanas funcionen como una red completa, reduciendo los tiempos de espera globales de los peatones y los retrasos en las calles secundarias. Se requiere un tiempo mínimo de fase de 7 segundos , y los tiempos de cruce deben basarse en una velocidad mínima de cruce de 2,5-3,5 pies por segundo National Association of City Transportation Officials (2025). Esta consideración es especialmente importante para acomodar a personas mayores y niños que pueden necesitar más tiempo para cruzar.

Estudios de psicología del conductor demostraron que tiempos verdes inferiores a 15 segundos generan frustración y aumentan violaciones semafóricas Brosseau et al. (2013).

Para el tiempo verde mínimo, la fórmula recomendada por la Federal Highway Administration (2009), considera factores peatonales:

$$T = \frac{A}{V} + \frac{W}{V_p} \quad (16)$$

Donde:

- A representa la distancia de partida.
- K el ancho de la calle y V_p la velocidad peatonal.

2.1. Tiempo verde máximos

Akçelik (1980), desarrolló expresiones dependientes del tiempo para el retraso, la tasa de paradas y la longitud de cola en señales de tráfico, proporcionando modelos de trabajo simples para predecir las características operativas del tráfico. Estos modelos son fundamentales para comprender cómo los tiempos de señal afectan el rendimiento del tráfico.

Cuando los tiempos de espera son excesivos, los peatones frecuentemente cruzan la calle por frustración antes de recibir una señal de pase (WALK). Investigaciones han mostrado que los peatones se vuelven impacientes cuando experimentan retrasos mayores a 60 segundos, y su disposición a tomar riesgos aumenta, intensificándose la tasa de violaciones de señales Turner et al. (2008).

Estos hallazgos sugieren que los tiempos verdes demasiado largos para una dirección del tráfico pueden generar comportamientos peligrosos en los peatones que esperan en la dirección contraria.

3. Tiempo ámbar adaptativo por densidad

3.1. Fórmula ITE (Institute of Transportation Engineers)

El concepto de zona de dilema asociada a la luz en ambar es ampliamente reconocido como un área en la aproximación a una intersección de alta velocidad, donde los vehículos no pueden ni detenerse con seguridad antes de la línea de parada ni

atravesar la intersección durante el intervalo ámbar Zhang et al. (2014).

La ecuación estándar del ITE para calcular el tiempo ámbar se basa en principios físicos. Esta fórmula considera el tiempo de percepción-reacción, la velocidad del vehículo, la desaceleración y el efecto de la pendiente:

$$t = t_1 + \frac{v}{2a + 2gG} \quad (17)$$

Donde:

- t_1 representa el tiempo de percepción-reacción, v la velocidad.
- a la desaceleración, g la gravedad, G la pendiente.

3.2. Investigaciones de Zegeer sobre probabilidad de parada

Zegeer y Deen (1978) estudiaron la probabilidad de detención de los conductores al inicio del ámbar. Su enfoque basado en frecuencias utiliza el porcentaje de conductores que se detienen para una distancia/tiempo dado desde la línea de parada y la velocidad del vehículo para desarrollar las curvas de la zona de dilema.

Diversos factores influyen en las curvas de la zona de dilema, como la velocidad del vehículo, la distancia a la línea de parada, la clase del vehículo, la posición del carril y la aceleración al inicio de la fase ámbar, entre otros factores.

Los estudios han utilizado el enfoque de regresión logística binaria para modelar la decisión de detenerse o continuar la marcha durante la fase ámbar e identificar la zona de dilema. Una zona de dilema en la intersección señalizada se define donde más del 10 % y menos del 90 % de los conductores toman decisiones de detenerse.

4. Modelación de saturación y ajustes adaptativos

4.1. Modelo de Webster basado en la teoría de colas

El modelo de Webster es efectivamente un fundamento importante del comportamiento no lineal en la relación entre demora y saturación. Webster desarrolló sus ecuaciones, que siguen siendo la base de la planificación de señales de tráfico hasta la actualidad, siendo utilizadas en manuales como el HCM.

El modelo demuestra que la relación entre demora y grado de saturación sigue una curva exponencial y no una relación lineal, especialmente cuando el sistema se acerca a la saturación. Los modelos de demora en intersecciones señalizadas confirman esta naturaleza no lineal, donde la demora uniforme y la demora por exceso de flujo aumentan significativamente a medida que el grado de saturación ($X = v/c$) se acerca o supera el valor de 1.0. Webster (2004).

4.2. Modelo de Shockwave de Lighthill-Whitham-Richards (LWR)

El modelo de Lighthill-Whitham-Richards (LWR) es un fundamento teórico legítimo para el comportamiento no lineal en condiciones de saturación de tráfico. Este modelo es un modelo de flujo de tráfico macroscópico de primer orden que captura

ondas de choque cinemáticas y ondas de rarefacción en el flujo de tráfico, siguiendo leyes de conservación hiperbólicas escalares. El modelo LWR demuestra que la propagación de ondas de choque en el tráfico tiene comportamiento no lineal, especialmente cerca de la saturación.

4.3. Estudios de Akçelik sobre comportamiento en saturación

Akçelik (1980) desarrolló una función general de demora para componentes que demuestra claramente la relación no lineal entre el grado de saturación y la demora experimentada.

La fórmula de demora de Akçelik ha sido modificada para adaptarse a diferentes condiciones de tráfico y ha servido como base para posteriores desarrollos de modelos de demora que tienen en cuenta la respuesta no lineal a la saturación.

Los trabajos de Akçelik demuestran que la respuesta óptima a saturaciones crecientes debe ser no lineal, con mayor sensibilidad en grados de saturación altos.

5. Incremento proporcional y equidad en asignación

5.1. Principio de compensación de Webster

Webster desarrolló un método racional para el diseño de señales de tráfico que incluye una fórmula para calcular la longitud óptima del ciclo en una intersección. Su fórmula se expresa como: Longitud óptima del ciclo (C_o) = $(1.5 \cdot L + 5) / (1 - y)$, donde L representa el tiempo perdido total y y es la suma de las razones de flujo críticas.

Webster (2004) propuso una ecuación para calcular la longitud del ciclo que busca minimizar la demora vehicular. Esta longitud óptima del ciclo tiene como objetivo distribuir el tiempo verde de manera que los índices v/c (volumen/capacidad) se igualen entre los grupos de carriles críticos. El principio establece que las intersecciones con accesos altamente saturados requieren asignaciones de tiempo proporcionalmente mayores.

5.2 Modelo de minimización de demoras HCM (Highway Capacity Manual)

El Highway Capacity Manual (HCM) efectivamente establece modelos para la minimización de demoras que respaldan la idea de que la asignación óptima de tiempos verdes debe incrementarse en proporción directa al grado de saturación.

El HCM define métodos para la determinación del nivel de servicio en intersecciones señalizadas, incluyendo modelos que consideran la relación entre demora y grado de saturación (v/c). Estos modelos muestran que la demora aumenta de manera no lineal a medida que aumenta el grado de saturación.

El HCM (2016) incluye factores de progresión para modelos de demora y cola en señales de tráfico, que han sido formalmente aprobados por el Comité de Capacidad de Carreteras y Calidad de Servicio del TRB (Transportation Research Board).

Los modelos del HCM establecen claramente que para minimizar la demora total en

una intersección, es necesario ajustar los tiempos de verde en proporción a los flujos vehiculares, dando mayor tiempo a las aproximaciones con mayor saturación.

6. Factor de escala por demanda total

6.1 Modelo de ciclo óptimo de Webster

El modelo de ciclo óptimo de Webster efectivamente establece que la duración total del ciclo debe aumentar con el volumen total de tráfico, lo que fundamenta el uso de un factor de escala basado en la demanda total.

Los resultados de simulación demuestran que el método de Webster sobreestima la longitud óptima del ciclo y produce estimaciones de longitud de ciclo poco realistas cuando la relación volumen-capacidad del tráfico excede el 50 %.

Esta ecuación muestra claramente que cuando aumenta el volumen total de tráfico, la duración óptima del ciclo también debe aumentar, lo que proporciona una base teórica sólida para aplicar un factor de escala relacionado con la demanda total. Rakha y Farzaneh (2019).

6.2 Teoría de flujo inestable de May

La teoría de flujo inestable de May efectivamente demuestra que las intersecciones con mayor volumen total requieren ciclos más largos para mantener la estabilidad del flujo.

May (1990) desarrolló modelos de flujo de tráfico que identifican cómo los sistemas de tráfico pueden volverse inestables cuando el volumen aumenta, lo que justifica la necesidad de ciclos más largos para mantener la estabilidad operativa en intersecciones de alto volumen.

6.3 Estudios de microsimulación TRANSYT

Los estudios realizados con el software TRANSYT confirman que las intersecciones de alto volumen total requieren factores de escala adicionales, independientes del grado de saturación.

El modelo de simulación TRANSYT es ideal para estudiar el comportamiento de una red sobresaturada, porque modela todo el período de tiempo modelado, no solo un solo ciclo promedio.

Las comparaciones entre modelos de microsimulación y modelos tradicionales como TRANSYT han mostrado que VISSIM produce resultados más robustos en comparación con LINSIG y TRANSYT, especialmente para condiciones de alta demanda de tráfico. Smith y Mounce (2011).

Los estudios de microsimulación realizados con TRANSYT han confirmado que factores de escala adicionales, más allá del grado de saturación, son necesarios para optimizar la operación de intersecciones con alto volumen total de tráfico.

3. MARCO METODOLÓGICO

3.1. Método

El método deductivo parte de premisas o teorías generales y las aplica a situaciones particulares.

En la presente investigación se apoya en modelos teóricos ya establecidos sobre modelamiento de tráfico, comportamiento vehicular y redes neuronales (conocimiento establecido y validado en el campo de la inteligencia artificial) y lo adaptamos a un problema específico de congestión vehicular en una ubicación concreta (Jirón Carlos F. Vivanco). Por lo que el método para la presente investigación será **deductivo**.

Este proceso de ir de lo general (teorías existentes) a lo particular (modelo específico) es característico del método deductivo.

3.2. Orientación

La investigación aplicada se caracteriza, por buscar soluciones prácticas a problemas identificados, a diferencia de la investigación básica que busca ampliar el conocimiento teórico sin necesariamente aplicarlo.

La investigación está directamente orientada a resolver un problema concreto y real que es la congestión vehicular, en una ubicación geográfica específica (Jirón Carlos F. Vivanco). Lo que es característico de la investigación **aplicada**.

3.3. Enfoque

La investigación se clasifica como **cuantitativa** por estos elementos esenciales:

- Se basa en la medición objetiva de variables numéricas específicas: conteo de vehículos, densidad vehicular y tiempos de ciclos semafóricos.
- Emplea técnicas matemáticas y estadísticas para el procesamiento de datos, particularmente algoritmos de redes neuronales convolucionales que analizan patrones numéricos en imágenes para la detección vehicular.
- Utiliza métricas precisas para la evaluación del desempeño del modelo: Porcentajes de precisión, recall, F1-score y exactitud de la detección, que permiten validar objetivamente los resultados.

Este enfoque garantiza la rigurosidad metodológica necesaria para desarrollar un sistema de control de tráfico basado en evidencia cuantitativa, capaz de optimizar objetivamente el tráfico vehicular en el Jirón Carlos F. Vivanco.

3.4. Instrumento de recolección de datos

Las redes neuronales artificiales requieren datos de alta calidad y en formatos específicos. Debido en la presente investigación, instalamos dos cámaras de vigilancia, mediante el uso de estas capturamos ciclos completos de tráfico (horas pico, variaciones

diarias, patrones semanales) que son esenciales para el entrenamiento adecuado de una red neuronal.

Al diseñar nuestra propia recolección de datos, nuestra investigación es **proelectiva**.

3.5. Tipo o alcance de la investigación

Una investigación explicativa va más allá de la descripción de fenómenos y busca establecer las causas o factores que producen determinados efectos. La presente investigación no solo pretende describir la congestión vehicular, sino entender qué factores la causan y cómo interactúan entre sí para poder modelarlos mediante redes neuronales. El desarrollo del modelo implica la formulación y verificación de hipótesis sobre las relaciones entre variables, lo que es un elemento definitorio de los estudios **explicativos**.

3.6. Nivel de investigación

La presente investigación está enfocada en resolver un problema concreto y tangible (la congestión vehicular) en un contexto específico. No se queda en el ámbito teórico sino que busca una aplicación directa del conocimiento. Emplea herramientas tecnológicas avanzadas (redes neuronales artificiales) con el propósito específico de modificar una situación real que afecta a la población, por lo cual la tesis de acuerdo al nivel es **aplicativa**. Aunque no se implementa físicamente el prototipo del controlador semafórico, el modelo será validado con datos reales del tráfico en Ayacucho, lo que permitirá evaluar su eficacia potencial. Este proceso de validación enfocado en la aplicabilidad práctica reafirma su naturaleza aplicativa.

3.7. Diseño de investigación

3.7.1. Propósito de la investigación

La presente investigación finaliza con una propuesta basada en el modelo, pero no incluye la aplicación real de estas recomendaciones para verificar sus efectos.

Si bien se desarrolla un modelo computacional basado en redes neuronales artificiales que simula y predice, los ciclos semafóricos en función de la densidad de los vehículos, no se llega a la fase de implementación física mediante semáforos inteligentes u otros dispositivos de control, por lo cual la investigación, de acuerdo al propósito de la investigación es **no experimental-observacional**.

3.7.2. Número de mediciones

El modelo que propone la investigación, se basa en los datos recopilados en un momento específico. Estos datos se utilizan para entrenar y validar el modelo de redes neuronales, por ello solo se realiza una medición única. Aunque el modelo podría usarse para predecir o gestionar el tráfico en el futuro, la base de datos inicial para su creación y validación proviene de una única medición. A razón de ello la investigación de acuerdo al número de mediciones es **transversal**.

3.7.3. Cronología de las observaciones

Un diseño de investigación prospectivo se caracteriza por iniciar con la identificación de una población o situación en el presente y luego seguirla a lo largo del tiempo para observar eventos o resultados futuros. En otras palabras, la investigación se dirige “hacia adelante” el objetivo principal de la presente investigación es crear un modelo que tenga un impacto futuro en la reducción de la congestión vehicular. Estás diseñando una solución que se implementará y evaluará en el futuro. a razón de ello la investigación de acuerdo a la cronología de las observaciones es **prospectivo**.

3.8. Estudio del diseño de investigación

En un Estudio de Cohortes, se observa un grupo de sujetos a lo largo del tiempo para analizar cómo ciertos factores influyen en un resultado determinado. En la presente investigación analizamos el tráfico vehicular antes y después de la aplicación del modelo basado en redes neuronales, evaluando su impacto en la reducción de la congestión, debido a ello de acuerdo al estudio del diseño de investigación la presente investigación se alinea más al **estudio de Cohortes**.

3.9. Población y muestra

3.9.1. Población

La población del estudio está constituida por el conjunto total de 5,000 imágenes de vehículos capturadas en el Jirón Carlos F. Vivanco, Ayacucho. Estas imágenes fueron obtenidas mediante observación sistemática no participante en diferentes puntos estratégicos a lo largo de la vía, abarcando diversas franjas horarias (mañana, tarde y noche), así como condiciones climatológicas variables. La población incluye registros fotográficos de todos los tipos de vehículos que circulan por dicha arteria, captados durante episodios de congestión alta, media y baja. Esta colección completa de imágenes constituye el universo inicial desde el cual se realizó posteriormente el proceso de selección para obtener la muestra de entrenamiento del modelo de redes neuronales artificiales.

3.9.2. Muestra

La muestra fue seleccionada mediante un muestreo no probabilístico intencional, conformada por 3,000 imágenes extraídas de una población de 5,000 fotografías capturadas en el Jirón Carlos F. Vivanco. Los criterios de selección se enfocaron en garantizar la representatividad de las diversas condiciones de tráfico (horas pico, flujo normal, baja densidad), variedad de vehículos, y calidad técnica de las imágenes adecuada para el entrenamiento de redes neuronales artificiales. Este tipo de muestreo permitió asegurar la inclusión de casos que representan la heterogeneidad del tránsito vehicular en la zona estudiada.

3.10. Hipótesis

3.10.1. Hipótesis general

El modelo de tráfico vehicular, basado en Redes Neuronales Artificiales, reduce significativamente la congestión vehicular en el Jirón Carlos F. Vivanco, distrito de Ayacucho, 2024.

3.10.2. Hipótesis específicas

1. El diseño del modelo basado en Redes Neuronales Artificiales (RNA) permite ajustar una arquitectura , para la detección,clasificación y conteo eficiente de vehículos, en condiciones heterogéneas, que incluyen tráfico variable, diversas condiciones ambientales (precipitaciones, iluminación solar variable, sombras proyectadas) y entornos nocturnos con visibilidad limitada.
2. El entrenamiento del modelo,basado en Redes Neuronales Artificiales (RNA), logra un equilibrio óptimo entre la precisión en la detección, la exhaustividad en el reconocimiento de vehículos y la robustez contra el sobreajuste.
3. La implementación del modelo basado en Redes Neuronales Artificiales (RNA) permite desarrollar un algoritmo, que optimiza la duración de los ciclos en función de la densidad vehicular bajo condiciones variables de tráfico.

3.11. Operacionalización de variables

3.11.1. Variables

Caballero Romero (2014) define una variable como un conjunto de datos que comparten una característica, propiedad o atributo específico, lo que los incluye dentro del ámbito de esa variable. En el contexto estadístico, una variable se entiende como un símbolo que representa un conjunto determinado de datos, capaz de asumir cualquier valor dentro de ese conjunto.

Existen básicamente dos variables que participan de todo proceso de investigación conocidas como; variables independientes y dependientes.

- **Variable independiente (X): Modelo de tráfico vehicular** : Es el factor que el investigador manipula o controla para observar su efecto en otra variable.
- **Variable dependiente (Y): Congestión vehicular** :Es el factor que el investigador mide y se espera que sea afectado por la manipulación de la variable independiente.

3.11.2. Dimensiones

Según Valencia Gutiérrez et al. (2023), el concepto de dimensiones se refiere a los componentes o aspectos específicos que conforman una variable compleja. Las dimensiones representan subdivisiones de un concepto o variable que permiten analizarla de manera más precisa y detallada.

■ **Variable independiente (X): Modelo basado en Redes Neuronales Artificiales (RNA)**

- **Dimensión 1:** Arquitectura del modelo, Se refiere a la configuración específica de las capas, el tipo de neuronas y las conexiones entre ellas dentro de la Red Neuronal Artificial (RNA) para el análisis del tráfico vehicular.
- **Dimensión 2:** Diseño del modelo, Es la planificación detallada y la especificación de la arquitectura de la Red Neuronal Artificial (RNA), incluyendo la selección de tipos de capas, número de neuronas por capa, funciones de activación y conexiones, con el objetivo de optimizar el proceso de aprendizaje para una tarea específica, como la detección y clasificación vehicular.
- **Dimensión 3:** Entrenamiento del modelo, Es el proceso iterativo mediante el cual se ajustan los parámetros internos (pesos y sesgos) de la Red Neuronal Artificial (RNA) utilizando un conjunto de datos etiquetados, a través de algoritmos de optimización y técnicas de regularización, con el objetivo de minimizar la función de pérdida y lograr un rendimiento óptimo en la tarea de análisis del tráfico vehicular.
- **Dimensión 4:** Resultados e implementación del modelo, Los resultados son las métricas cuantitativas y cualitativas (precisión, recall, F1-score, velocidad de inferencia) que miden el rendimiento de la RNA tras su entrenamiento para análisis de tráfico. La implementación es el proceso de integrar esta RNA entrenada en un sistema práctico, aplicando la arquitectura y parámetros optimizados para funcionar en situaciones reales de tráfico vehicular.

■ **Variable dependiente (Y): Congestión vehicular**

- **Dimensión 1:** Índice de la congestión, Evalúa el nivel de saturación de una vía o red vial en un momento dado. Compara el flujo de tráfico real con el flujo máximo que la vía puede soportar, y así determinar si existe un problema de congestión.
- **Dimensión 2:** Evaluación de la congestión, Mide y analiza el nivel de saturación de una vía o red vial en un momento dado a través de métodos directos (mediciones de campo, sistemas de detección) y métodos indirectos (encuestas a usuarios, análisis de datos administrativos, modelos de simulación).
- **Dimensión 3:** Análisis de la congestión, Implica la recopilación, el procesamiento y la interpretación de datos relacionados con el tráfico vehicular, con el objetivo de identificar patrones, cuantificar la magnitud del problema y evaluar el impacto de diferentes medidas de mitigación.
- **Dimensión 4:** Comparación con métodos tradicionales: Evaluación del modelo RNA en comparación con modelos convencionales de tráfico vehicular.

3.11.3. Indicadores

Caballero Romero (2014) define los indicadores como elementos especificadores y referenciales que ayudan a precisar, identificar, separar y usar los datos. Pueden medirse directamente de la realidad, por lo general como tasas, por ejemplo: tasas de nacimientos, de mortalidad.

3.11.3.1 Indicadores independientes:

1. Arquitectura del modelo:
 - Número de capas de la red neuronal, [Número entero (número de capas-Conteo (n))].
 - Tipo de capas, [Categoría (tipos de capas)].
 - Tamaño de las capas, [Número entero (número de neuronas o filtros por capa)].
 - Función de activación, [Categoría (tipos de funciones)].
2. Diseño del modelo:
 - Tasa de aprendizaje, [Valor decimal (learning rate)].
 - Número de épocas de entrenamiento, [Número entero (número de épocas)].
 - Momento (momentum), [Valor decimal (momentum)].
 - Factor de decaimiento del aprendizaje. (learning rate decay), [Valor decimal (decay rate)].
3. Entrenamiento del modelo:
 - Algoritmo de optimización, [Categoría (SGD, Adam, RMSprop)].
 - Técnicas de regularización, [Categoría (dropout, L2 regularization, early stopping)].
 - Estrategias de aumento de datos, [Categoría (rotación, escalado, traslación)].
 - Esquema de aprendizaje, [Categoría (step decay, exponential decay, adaptive)].
 - Precisión en la validación y entrenamiento [Porcentaje (%)].
 - Pérdida en la validación y entrenamiento [Valor numérico (cross-entropy loss, mean squared error)].
 - Tiempo total de entrenamiento [minutos (min)].
 - Curva de aprendizaje [Gráfico (eje X: épocas, eje Y: precisión/pérdida)].
 - Pesos del modelo Matriz de valores numéricos [(weights matrix)].
 - Bias del modelo Vector de valores numéricos [(bias vector)].
 - Sobreajuste (overfitting) [Porcentaje (%)].
4. Resultados e implementación del modelo:
 - Plataforma de Software, [Rendimiento (Porcentaje (%))].
 - Entorno de Simulación, [Categoría (sistema)].
 - Predicción de la congestión, [Número de vehículos por tipo (veh/tipo)].
 - Optimización de los ciclos semafóricos, [Tiempo (segundos)].

3.11.3.2 Indicadores dependientes:

1. Índice de la congestión:
 - Número de vehículos por tipo, [Vehículos por tipo (veh/tipo)].
2. Evaluación de la congestión:
 - Velocidad promedio de los vehículos, [(km/h)].
 - Velocidad máxima registrada, [(km/h)].
 - Velocidad mínima registrada, [(km/h)].

3. Análisis de la congestión:

- Reducción del tiempo de viaje y mejora en el flujo vehicular [(veh/tiempo)].

4. Comparación con métodos tradicionales:

- Reducción de tiempo, [Porcentaje (%)].
- Precisión de detección, [Porcentaje (%)].
- Consumo de recursos, [Porcentaje (%)].

En los anexos se presenta la operacionalización de las variables identificadas, donde se detalla las variables, indicadores, dimensiones y sus unidades de medida.

3.12. Técnicas e instrumentos.**3.12.1. Técnicas de recolección**

En el desarrollo de esta investigación, se recurrió a una variedad de métodos para la recolección y el análisis de la información, así como para la creación y la evaluación del modelo basado en redes neuronales convolucionales implementando la arquitectura YOLO. Las técnicas específicas empleadas en este estudio se describen a continuación.

1. **Revisión bibliográfica y documental:** Se basa en la compilación y evaluación de material publicado referente a visión artificial, metodologías de redes neuronales convolucionales y sistemas algorítmicos para la predicción de ciclos semafóricos. Este estudio se ejecutó mediante el acceso a repositorios científicos como IEEE Xplore, Google Scholar, Scopus, Springer y Sci Hub, además de obras especializadas y documentación técnica del campo.
2. **Análisis exploratorio de datos (EDA):** El análisis exploratorio de datos en la presente investigación examinó el flujo vehicular en Jirón Carlos F. Vivanco, analizando tipos de vehículos, patrones temporales y la infraestructura vial existente. Se establecieron correlaciones entre el UCP y el tipo de vehículo, y se organizaron adecuadamente los datos para entrenar la Red Neuronal Artificial, específicamente la CNN para detección y clasificación vehicular.
3. **Desarrollo y entrenamiento del modelo de RNA:** Se implementó un sistema de redes neuronales convolucionales con YOLO para la identificación y categorización de vehículos, implementando plataformas de aprendizaje profundo como TensorFlow y Keras, junto con equipos GPU especializados para optimizar el proceso de entrenamiento.
4. **Validación del modelo:** Análisis de la efectividad del sistema de Redes Neuronales Artificiales mediante un grupo de información independiente no utilizado en la fase de aprendizaje. Se aplicarán indicadores de desempeño como exactitud, sensibilidad, puntuación F1 y tablas de confusión para la valoración.
5. **Implementación y pruebas de campo:** Aplicación del sistema de Redes Neuronales Artificiales en el Jirón Carlos F. Vivanco para medir su funcionamiento en escenarios reales. Se emplearán equipos de registro visual como cámaras con alta definición.

3.12.2. Instrumentos utilizados

Para la implementación de las técnicas mencionadas, se utilizaron diversos instrumentos:

- **Creación de bases de datos a partir de la recolección de imágenes de vehículos:**
 - **Recolección de datos en campo:** Obtención de fotografías de automóviles circulando por el Jirón Carlos F. Vivanco, desde diversas perspectivas y posiciones. La recolección de un extenso conjunto de información se realizó mediante el uso de un par de dispositivos fotográficos de la marca IMOU.
 - **Características-Cámara 01:** Es una cámara IMOU modelo Cruiser, una cámara de vigilancia IP, con características avanzadas para la seguridad y el monitoreo. Con una resolución en HD que garantiza imágenes nítidas y detalladas, cuenta con visión nocturna avanzada, con un alcance de hasta 100 m, presenta diferentes modos para adaptarse a las condiciones de iluminación, certificación IP66, que la protege contra el polvo y la lluvia, permitiendo que las imágenes capturadas sean de una calidad avanzada, presenta un Movimiento PTZ: Capacidad de paneo (hasta 355°) e inclinación (hasta 90°), lo que permite cubrir amplias áreas y eliminar puntos ciegos.
 - **Características-Cámara 02:** Es una cámara IMOU del modelo IPC-K7C-H1WE (Cruiser SE+) , es una cámara de vigilancia con características avanzadas diseñadas para proporcionar seguridad y monitoreo confiable. Con una resolución de 3k, que garantiza imágenes nítidas y detalladas, Permite obtener imágenes claras incluso en la oscuridad, con colores realistas, gracias a su visión nocturna a color, presenta diferentes modos para adaptarse a las condiciones de iluminación, certificación IP66, que la protege contra el polvo y la lluvia, permitiendo que las imágenes capturadas sean de una calidad avanzada, presenta un Movimiento PTZ: Capacidad de paneo (hasta 355°) e inclinación (hasta 90°), lo que permite cubrir amplias áreas y eliminar puntos ciegos.
 - **Software de análisis de datos:** Herramientas y bibliotecas de programación para el análisis exploratorio y la preparación de datos. Ejemplos incluyen Python (Pandas, NumPy, Matplotlib, Seaborn).
 - **Frameworks de deep learning:** Entornos de desarrollo para la creación, entrenamiento y evaluación de modelos de redes neuronales (Ultralytics YOLO).
 - **Hardware especializado:** Equipos con alta capacidad de procesamiento, como GPUs (NVIDIA) y TPUs (Google Colab), para acelerar el entrenamiento de modelos de deep learning.

3.12.3. Herramientas de software utilizadas

En esta investigación se hará uso de diversas herramientas de software, detalladas a continuación:

Cuadro 3: Herramientas de software utilizadas

Herramienta	Descripción
LaTeX	Preparación de documentos para la redacción del informe final
Anaconda	Distribución de Python para el análisis de datos y desarrollo de modelos
Ultralytics YOLO	Algoritmo de detección de objetos utilizado en el modelo CNN
TensorFlow & Keras	Frameworks de deep learning para el desarrollo y entrenamiento de modelos CNN
Python	Bibliotecas para el análisis de datos y visualización
SciPy & StatsModels	Bibliotecas de Python para análisis estadístico

Fuente: Elaboración propia

3.13. Desarrollo del trabajo de tesis

3.13.1. Recopilación de datos

Para la obtención de nuestro conjunto de datos, efectuamos la instalación de dos cámaras de vigilancia en el Jirón Carlos F. Vivanco, así mismo; un sistema de internet que nos permite la visualización en tiempo real, de los vehículos que transiten por este mencionado sector a través del aplicativo-IMOU LIFE.

1. Instalación de las cámaras de vigilancia

- **Permisos de aprobación:** La instalación requirió la aprobación de diversas subgerencias de la Municipalidad Provincial de Huamanga. Esto demuestra la necesidad de coordinación entre diferentes departamentos para proyectos de esta naturaleza. Las subgerencias involucradas fueron: Subgerencia de Tránsito y Seguridad Vial, Subgerencia de Serenos y la Unidad de Tecnologías de Información y Comunicaciones (UTIC).
- **Análisis de características:** La municipalidad realizó un análisis detallado de las características técnicas de las cámaras. Esto subraya la importancia de garantizar que el equipo sea adecuado para el entorno y cumpla con los requisitos de seguridad. Los aspectos analizados incluyeron: Peso de las cámaras, consumo de energía y el uso de un sistema propio.
- **Diseño un brazo rígido (de soporte):** Para permitir la estabilidad y la fijación segura de las cámaras, se diseñó un brazo rígido de montaje. La estabilidad y fijación, son fundamentales para la adquisición de imágenes nítidas y confiables, incluso ante condiciones climáticas adversas. Esta estabilidad

no solo asegura la calidad visual de los datos capturados, sino que también permite el ajuste preciso del enfoque y el ángulo de las cámaras, garantizando la obtención de información vehicular precisa y relevante para el análisis del tráfico.



Figura 23: Diseño del brazo rígido de soporte
Fuente: Imagen propia.

- **Uso del camión grúa para la instalación:** La instalación requirió personal de campo con experiencia en este tipo de trabajos el cual uso en todo momento Equipos de Protección Personal (EPP) de seguridad, lo que demuestra el cumplimiento de las normas de seguridad laboral. Adicionalmente, el empleo de un camión grúa para elevar y posicionar los equipos de videovigilancia señala la inaccesibilidad de los puntos de montaje por medios convencionales y la necesidad de utilizar maquinaria especializada para alcanzar las alturas y ubicaciones deseadas, garantizando así una instalación eficiente y segura de los dispositivos.




Figura 24: Uso del camión grúa para instalar las cámaras el Jirón Carlos F. Vivanco
Fuente: Imagen propia



Figura 25: Supervisión de la instalación de cámaras de vigilancia
Fuente: Imagen propia

2. Instalación del sistema de internet y ambiente de trabajo

- **Aprobación de la caseta de serenazgo:** Mediante coordinaciones con la municipalidad, se obtuvo el permiso para utilizar la caseta del observatorio de serenazgo como ambiente de trabajo. Este espacio resultó fundamental para llevar a cabo la captura y el monitoreo en tiempo real de las videograbaciones e imágenes necesarias para el proyecto.




Figura 26: Dirección del cableado de cámaras e internet a la caseta de serenazgo
Fuente: Imagen propia

- **Instalación del servicio de internet:** La instalación del servicio de internet WOW resultó crucial para la operatividad del sistema implementado y la visualización del flujo vehicular. Este componente fundamental permitió la correcta implementación y el funcionamiento continuo, asegurando la capacidad de monitorear el tráfico de manera efectiva.




Figura 27: Instalación del servicio de internet en el interior del observatorio
Fuente: Imagen propia

3. Determinación del enfoque, calidad, y ángulo de las cámaras

- Una vez instaladas las dos cámaras, se utilizó la aplicación IMOU LIFE para configurar su funcionamiento óptimo. A través de esta app, se ajustó el enfoque para obtener imágenes nítidas, se seleccionó la calidad de video deseada y se orientó el ángulo de cada cámara para cubrir las zonas de interés. Este proceso de ajuste fino garantizó una vigilancia efectiva de las áreas monitoreadas.
- **Cámara 01:** Ubicada estratégicamente en el Jirón Carlos F. Vivanco, captura vehículos con una perspectiva frontal en calidad HD, abarcando un amplio campo de visión de 100 metros. Esta configuración permite obtener imágenes detalladas de la parte delantera de los vehículos, facilitando su identificación y análisis para el monitoreo del tráfico.




Figura 28: Enfoque, calidad y ángulo-Cámara 01
Fuente: Imagen propia

- **Cámara 02:** Ubicada estratégicamente en la intersección del Jirón Carlos F. Vivanco y el Jr. Sol (óvalo del puente nuevo) en Ayacucho, captura vehículos con una perspectiva inclinada. Esta configuración permite obtener imágenes semilaterales y semidelanteras de alta calidad 3K, abarcando la totalidad de la curva del óvalo para un monitoreo completo del tráfico en esa zona.




Figura 29: Enfoque, calidad y ángulo-Cámara 02

Fuente: Imagen propia

4. Estrategia de recopilación de datos: Variación en horarios de congestión y condiciones ambientales diversas

- **Horarios de congestión y tráfico variable:** Para garantizar la robustez y fiabilidad del modelo de tráfico, la mayor cantidad de imágenes se capturó durante las horas pico (7:30-8:30 AM, 1:00-2:30 PM, 6:30-8:00 PM), pero también se recopiló una cantidad significativa de datos en periodos de menor congestión vehicular. Esta estrategia integral asegura que el modelo aprenda a reconocer patrones tanto en situaciones de tráfico denso como en condiciones de flujo vehicular diverso.



Figura 30: Fotografía registrada a las 12:41 horas por la cámara 01

Fuente: Imagen propia

- **Condiciones ambientales:** Se capturaron imágenes en diversas condiciones de iluminación, incluyendo días soleados, lluviosos, atardeceres, escenas nocturnas y contraluz. Esta diversa variedad de datos es fundamental para que el modelo aprenda a identificar objetos de manera confiable y precisa, independientemente de las condiciones lumínicas presentes.




Figura 31: Captura del flujo vehicular en entorno soleado
Fuente: Imagen propia




Figura 32: Captura del flujo vehicular en entorno nocturno
Fuente: Imagen propia




Figura 33: Captura del flujo vehicular en entorno lluvioso
Fuente: Imagen propia

- **Efectos de luz:** Se capturo tambien, los reflejos de las luces automotrices nocturnas, los cuales podrían interferir en la correcta detección vehicular por la red neuronal. Se prestó especial atención al efecto de contraluz, ya que las sombras proyectadas representan un desafío potencial para la precisión en la identificación de los vehículos.




Figura 34: Captura del flujo vehicular nocturno luces altas
Fuente: Imagen propia



Figura 35: Contraluz y sombras de casonas dificultan visibilidad del tráfico (11:20 am).
Fuente: Imagen propia

3.13.2. Conjunto de datos de entrenamiento

El modelo se entrenó con 3000 imágenes locales (JPG de cámaras 01 y 02) que cubren diversas condiciones de luz y clima (día, noche, lluvia, sol, variabilidad de horas). Esta variedad es clave para que el modelo sea altamente robusto incluso en situaciones difíciles, evitando depender solo de condiciones ideales.




Figura 36: Dataset de 3000 imágenes en formato jpg
Fuente: Imagen propia

3.13.3. Etiquetado en LabelMe

El etiquetado se realizó en el aplicativo, Labelme el cual es una herramienta de software de código abierto para anotación de imágenes, utilizada en proyectos de visión por computadora y aprendizaje automático.

A. Consideraciones del etiquetado en Labelme

- **Claridad en las categorías(clases):** Se definio claramente las categorías (clases) asegurandose de que no exista ambigüedad. Establecimos 8 categorías (clases) bien definidas, sin margen para la ambigüedad. Sus detalles se especificarán más adelante.
- **Consistencia y precisión:** Para lograr gran consistencia y precisión los polígonos o bounding boxes se dibujaron lo más ajustados posible a los objetos (vehículos) utilizando suficientes puntos para capturar la forma detallada.
- **Manejo de oclusiones:**
 - Visibilidad parcial:** Si el objeto está parcialmente ocluido, solo se etiqueto la parte visible del objeto.
 - Oclusión por otro objeto de la misma clase:** Si el objeto está ocluido por otro objeto de la misma clase, se etiquetó la parte visible de cada uno individualmente.
 - Oclusión por objeto de otra clase:** Se etiquetó solo la parte visible del objeto de interés.
- **Objetos borrosos o difíciles de definir:** Debido a que el conjunto de datos fueron de vehículos en movimiento, a veces por la velocidad de los mismos algunos resultan con imagenes borrosas, ante ello se etiquetó, la región visible del vehículo, teniendo en cuenta solo etiquetar la región visible del vehículo.

B. Definición de las categorías (clases)

Se define ocho categorías diferentes (clases) basadas en la unidad de coche patron (UCP) , utilizada en el PMUS-Huamanga, pero para el contexto del Jirón Carlos F. Vivanco:

Tabla 107 Equivalencia estándar de cada modo de transporte en UC

Modo	Unidad Coche Patrón (UCP)
Moto lineal	0.33
Mototaxi	0.75
Auto	1
Taxi	1
Camioneta Rural	1.25
Microbús	2
Ómnibus Interprovincial.	3
Camión 2E, 3E	2.5
Tráiler	3.5

Fuente: Grupo de Estudio FIC-UNI-GIZ

Figura 37: Valores UCP adaptados del PMUS-Huamanga
Fuente: Imagen propia

Cuadro 4: Definición de categorías (clases)

Código	Clasificación de vehículos
A	Autos (Auto/Station Wagon/Crossovers)
MB	Microbus
M	Motocicletas (Moto/Bicicleta)
CP	Camión Pequeño (C2/C3)
RC	Rural Combi (Combi/Panel)
PU	Camionetas (Pick UP/Pick UP Compactas/SUV compactos y medianos)
MT	Mototaxi/Motocargas
CG	Camión Grande (C4/8x4)

Fuente: Elaboración propia

C. Etiquetado con Segment Anything (Speed):

Realizamos el etiquetado con Segment Anything (Speed) debido a que poseemos un conjunto de datos con alta variación y congestionamiento vehicular, a continuación se detallan los beneficios para su consideración:

- **Generación de máscaras de segmentación precisas y mejor discriminación:** El uso de Segment Anything Model (SAM) es clave, para la clasificación y reconocimiento vehicular debido a que, en situaciones de alta congestión, donde los vehículos están muy cerca unos de otros, las bounding boxes pueden superponerse o incluir varios vehículos en una sola caja. SAM puede distinguir y segmentar cada vehículo individualmente, proporcionando al modelo información más clara sobre cada instancia.
- **Enriquecimiento de las características aprendidas y reducción del ruido:** Al entrenar con máscaras de segmentación, la red neuronal aprende a detectar las características más discriminativas para la clasificación y el reconocimiento de diferentes tipos de vehículos, incluso en condiciones de variabilidad (ángulo, iluminación, oclusión). Al eliminar los píxeles de fondo irrelevantes, el modelo se centra en aprender de las características propias de los vehículos. Esto conduce a un entrenamiento más eficiente y a modelos más robustos que son menos susceptibles a las variaciones del entorno.
- **Adaptabilidad a nuevos escenarios-transferencia sin disparos (zero-shot):** SAM funciona incluso en distribuciones de datos no vistas durante el entrenamiento, lo que es útil para condiciones únicas de Ayacucho (calles estrechas con tráfico caótico)
- **Escalabilidad para futuros proyectos:** Conocer exactamente cuántos vehículos hay por carril permite que los semáforos ajusten sus tiempos de forma inteligente, mejorando el tráfico y reduciendo los embotellamientos.

1. Etiquetado de la categoría (clase)-Auto (A)




Figura 38: Etiquetado de Auto-Station Wagon-Perspectiva inclinada
Fuente: Imagen propia.




Figura 39: Etiquetado de Auto-Perspectiva frontal
Fuente: Imagen propia

2. Etiquetado de la categoría (clase)- Microbus (MB)




Figura 40: Etiquetado de MicroBus-Perspectiva frontal
Fuente: Imagen propia




Figura 41: Etiquetado de MicroBus-Perspectiva inclinada
Fuente: Imagen propia

3. Etiquetado de la categoría (clase)-Motocicleta (M)




Figura 42: Etiquetado de Motocicleta-Perspectiva lateral
Fuente: Imagen propia




Figura 43: Etiquetado de Motocicleta-Perspectiva frontal
Fuente: Imagen propia

4. Etiquetado de la categoría (clase)-Camión Pequeño (CP)




Figura 44: Etiquetado de Camión pequeño-Perspectiva frontal
Fuente: Imagen propia

5. Etiquetado de la categoría (clase)-Rural Combi (RC)




Figura 45: Etiquetado de Camión pequeño-Perspectiva inclinada
Fuente: Imagen propia

6. Etiquetado de la categoría (clase)-Camionetas (PU)




Figura 46: Etiquetado de Camioneta Pick UP-Perspectiva inclinada
Fuente: Imagen propia

7. Etiquetado de la categoría (clase)-Mototaxi (MT)




Figura 47: Etiquetado de Mototaxi-Perspectiva Inclinada
Fuente: Imagen propia

8. Etiquetado de la categoría (clase)-Camión Grande (CG)




Figura 48: Etiquetado de Camión Grande-Perspectiva inclinada
Fuente: Imagen propia




Figura 49: Etiquetado final de una fotografía
Fuente: Imagen propia

D. Generación de los archivos con formato JSON

Después de realizar el etiquetado de las imágenes utilizando LabelMe, por cada imagen etiquetada, el programa genera un archivo con el mismo nombre de la imagen pero con la extensión .json. Estos archivos contienen toda la información sobre las etiquetas que se creó para esa imagen específica. Esta información generalmente incluye:

- **Shapes, shape type-label y points:** Los Shapes son una lista de diccionarios, donde cada diccionario representa un objeto etiquetado en la imagen, los shape type son tipo de forma utilizada para etiquetar (por ejemplo, polygon, rectangle, circle, line, point) en nuestro caso será polygon. Para cada objeto, se suele incluir un label, que es el nombre de la clase o categoría asignada al objeto y los points que son una lista de coordenadas (x, y) que definen el polígono (o bounding box, dependiendo de cómo se realizó el etiquetado) del objeto:
- **ImagePath, imageHeight, imageWidth:** ImagePath es la ruta del archivo original, ImageHeight es altura de la imagen en píxeles y imageWidth el ancho de imagen en píxeles.

Se generó 3000 archivos con la extensión J.JSON, estos archivos son la representación estructurada de las anotaciones y son la salida principal de LabelMe, se utilizarán posteriormente para entrenar el modelo de detección y seguimiento de objetos.

Nombre	Fecha de modificación	Tipo	Tamaño
2968.json	29/03/2025 19:34	Archivo de origen ...	1,104 KB
2969.json	29/03/2025 19:36	Archivo de origen ...	514 KB
2970.json	29/03/2025 19:39	Archivo de origen ...	551 KB
2971.json	29/03/2025 19:43	Archivo de origen ...	579 KB
2972.json	29/03/2025 19:48	Archivo de origen ...	525 KB
2973.json	29/03/2025 19:52	Archivo de origen ...	486 KB
2974.json	29/03/2025 19:55	Archivo de origen ...	480 KB
2975.json	29/03/2025 19:59	Archivo de origen ...	500 KB
2976.json	29/03/2025 20:02	Archivo de origen ...	492 KB
2977.json	29/03/2025 20:05	Archivo de origen ...	486 KB
2978.json	29/03/2025 20:14	Archivo de origen ...	571 KB
2979.json	29/03/2025 20:20	Archivo de origen ...	494 KB
2980.json	29/03/2025 20:28	Archivo de origen ...	496 KB
2981.json	29/03/2025 20:31	Archivo de origen ...	481 KB
2982.json	29/03/2025 20:36	Archivo de origen ...	508 KB
2983.json	29/03/2025 20:42	Archivo de origen ...	531 KB
2984.json	29/03/2025 20:52	Archivo de origen ...	1,115 KB
2985.json	29/03/2025 20:59	Archivo de origen ...	534 KB
2986.json	29/03/2025 21:06	Archivo de origen ...	929 KB
2987.json	29/03/2025 21:11	Archivo de origen ...	851 KB
2988.json	30/03/2025 08:26	Archivo de origen ...	838 KB
2989.json	30/03/2025 08:35	Archivo de origen ...	601 KB
2990.json	30/03/2025 08:43	Archivo de origen ...	758 KB
2991.json	30/03/2025 08:48	Archivo de origen ...	521 KB
2992.json	30/03/2025 08:53	Archivo de origen ...	505 KB
2993.json	30/03/2025 09:01	Archivo de origen ...	498 KB
2994.json	30/03/2025 09:05	Archivo de origen ...	489 KB
2995.json	30/03/2025 09:14	Archivo de origen ...	1,104 KB
2996.json	30/03/2025 09:18	Archivo de origen ...	501 KB
2997.json	30/03/2025 09:21	Archivo de origen ...	514 KB
2998.json	30/03/2025 09:24	Archivo de origen ...	487 KB
2999.json	30/03/2025 09:35	Archivo de origen ...	1,133 KB
3000.json	30/03/2025 09:44	Archivo de origen ...	906 KB

Figura 50: Archivos generados con extensión J.JSON
Fuente: Imagen propia

3.13.4. Preprocesamiento-conversión de J.JSON a archivos Yolo

Tras la obtención de 3000 archivos de anotación en formato JSON, se realizó su conversión a formato YOLO mediante la ejecución del siguiente comando:

Código:

```
labelme2yolo --json_dir "C:\Users\LENOVO\Desktop\consolidado"
```

Figura 51: Código de conversión de J.JSON a archivos Yolo
Fuente: Imagen propia

Con el objetivo de entrenar eficazmente el modelo YOLO y evaluar su capacidad de generalización, el conjunto de datos se dividió en una proporción de 70 % para entrenamiento y 30 % para validación. Esta separación es crucial para evitar el sobreajuste y obtener una métrica fiable del rendimiento.

1. Carpeta train (entrenamiento)

Esta carpeta contiene el 70 % del conjunto de datos (2100) y se utiliza para entrenar directamente el modelo de detección de objetos. El modelo aprende a identificar patrones, características y relaciones entre las imágenes y sus correspondientes anotaciones (bounding boxes y etiquetas) a partir de los datos en esta carpeta.

- **Subcarpeta images:** Contiene los archivos de imagen que se utilizarán para el entrenamiento.
- **Subcarpeta labels :** Contiene los archivos de texto con las anotaciones correspondientes a cada imagen en la carpeta images. Contiene archivo .txt el cual contiene la información de los bounding boxes y las clases de los objetos presentes.

2. Carpeta val (validación)

Esta carpeta contiene el 30 % del conjunto de datos (900) datos que no se utiliza directamente durante el proceso de entrenamiento el cual se emplea para evaluar el rendimiento del modelo entrenado en datos "nuevos" que no ha visto antes. Esto permite monitorear el progreso del entrenamiento, durante el entrenamiento, el modelo se evalúa periódicamente con los datos de validación para ver cómo generaliza a datos no vistos. Esto ayuda a identificar si el modelo está aprendiendo correctamente o si está comenzando a sobreajustarse a los datos de entrenamiento.

- **Subcarpeta images:** Un conjunto de archivos de imagen diferentes a los de la carpeta train.
- **Subcarpeta labels :** Los archivos de texto con las anotaciones correspondientes a las imágenes en la carpeta images de val, en el mismo formato que los de la carpeta train.




Figura 52: Carpetas de archivos train y val
Fuente: Imagen propia

3. Archivo dataset.yaml

El archivo dataset.yaml brinda la ubicación del conjunto de datos, las clases de objetos que deseas detectar y otra información relevante para el entrenamiento y la validación del modelo. Su propósito principal es informar a YOLO dónde encontrar las imágenes y las etiquetas de tu dataset y cómo interpretarlas.




Figura 53: Contenido del archivo dataset.yaml
Fuente: Imagen propia

Tras obtener las carpetas de validación (val) y entrenamiento (train), se procedió a su almacenamiento en Google Drive. Dada la considerable cantidad de datos requerida para el entrenamiento de modelos, especialmente imágenes y anotaciones, y las limitaciones de almacenamiento y recursos computacionales del equipo local, se optó por utilizar Google Colab para el entrenamiento, facilitando así el acceso a los archivos desde la nube. Es importante señalar que el archivo dataset.yaml fue igualmente adaptado para que las rutas de las carpetas apuntaran a su ubicación en Google Drive.

3.13.5. Entrenamiento para la clasificación y detección en Google Colab

Se seleccionó YOLOv8m (medium) para el entrenamiento debido a sus beneficios superiores en la detección y clasificación de vehículos: una mayor precisión (mAP50) esencial para diferenciar vehículos similares o parcialmente visibles, un manejo de escala optimizado por su backbone y neck avanzados, capacidad de segmentación precisa de los contornos vehiculares y mayor robustez ante las variaciones de las imágenes. La siguiente tabla compara YOLOv8n (Nano) con YOLOv8m (Medium).

Cuadro 5: Comparativa YOLOv8n (Nano) con YOLOv8m (Medium).

Característica	YOLOv8n (Nano)	YOLOv8m (Medium)
Parámetros	3.3M	26.4M
FLOPs	9.2B	81.0B
mAP50 (precisión)	80.1 %	88.8 %
Velocidad CPU (ms)	131.8	456.3
Casos de uso	Tiempo real básico	Detección precisa

Fuente: Adaptado de Duc et al. (2024).

El proceso de entrenamiento se llevó a cabo con varias configuraciones de épocas: 1, 20, 50 y 100, buscando prevenir el sobreajuste. Los resultados completos se muestran para 150 épocas. La elección de 126 épocas como un punto clave se fundamenta en la intervención del Early Stopping, que indicó el momento óptimo para detener el entrenamiento.

1. Entrenamiento 150 épocas

■ 1.1. Análisis multidimensional

- **Gráfico de barras:** Muestra la distribución de frecuencias por categorías. Esta distribución sugiere una clasificación natural del fenómeno estudiado (vehículos que transitan por el Jiron Carlos F. Vivanco) donde ciertas categorías son intrínsecamente más comunes.




Figura 54: Gráfico de barras-150 épocas
Fuente: Imagen propia generada en Python

Cuadro 6: Distribución de instancias por categoría de vehículo

Categoría	Número de instancias
A (Autos)	Aproximadamente 15,000
M (Motocicletas)	Cerca de 12,500
MB (Microbus)	Alrededor de 4,400
PU (Camionetas)	Aproximadamente 1,800
MT (Mototaxi/Motocargas)	Cerca de 1,000
CP (Camión Pequeño)	Menos de 500
RC (Rural Combi)	Menos de 500
CG (Camión Grande)	Menos de 500

Fuente: Elaboración propia.

- **Gráfico-clustering o agrupamiento jerárquico:** Esta visualización muestra múltiples rectángulos superpuestos donde el algoritmo está enfocando su atención, indicando zonas de alta densidad de características o patrones relevantes de diferentes tamaños y colores.




Figura 55: Gráfico clustering o agrupamiento jerárquico-150 épocas

Fuente: Imagen propia generada en Python

- **Gráfico Mapa de calor X-Y:** Este mapa de calor muestra la distribución conjunta de dos variables (x,y) en el rango [0,1]. La mayor densidad (azul más oscuro) se concentra cerca del origen (0,0). Hay un patrón vertical interesante alrededor de $x \approx 0.4$ que muestra mayor intensidad.




Figura 56: Gráfico mapa de calor X-Y-150 épocas

Fuente: Imagen propia generada en Python

- **Gráfico Mapa de calor Width-Height:** Este mapa muestra la relación entre ancho (width) y alto (height). Existe una correlación positiva clara: a mayor ancho, mayor altura. La mayor concentración está en valores pequeños (cerca del origen). La distribución se estrecha a medida que aumentan los valores. Esto revela dimensiones de objetos detectados, donde la mayoría son pequeños, con relación de aspecto relativamente constante (proporción ancho/alto) para la mayoría de las instancias. Pocos objetos son muy grandes o muy anchos/altos.




Figura 57: Gráfico mapa de calor Width-Height-150 épocas

Fuente: Imagen propia generada en Python

■ 1.2. Análisis gráfico: Precision-Confidence Curve

Mediante la gráfica de precision-confidence se evalúa el rendimiento del modelo de detección de objetos o clasificación. Permite visualizar cómo varía la precisión del modelo a medida que ajustamos el umbral de confianza para cada una de las clases. Las clases se agrupan en diferentes niveles de rendimiento:




Figura 58: Gráfico: Precision-Confidence Curve-150 épocas

Fuente: Imagen propia generada en Python

• Clases de alto rendimiento (MT, MB, A):

- Alcanzan precisión superior a 0.8 incluso con niveles bajos de confianza (0.1-0.2).
- La clase MT (rosa) muestra el mejor rendimiento general.
- Estas clases tienen características muy distintivas que facilitan su detección.

- **Clases de rendimiento medio (M):**
 - Alcanza buena precisión pero requiere un umbral de confianza ligeramente mayor.
- **Clases de bajo rendimiento (CP, PU, RC, CG):**
 - Necesitan umbrales de confianza mucho más altos para lograr precisión aceptable.
 - La clase RC (púrpura) y CG (gris) son particularmente desafiantes para el modelo.

■ 1.3. Análisis gráfico: Recall-Confidence Curve

Estas gráficas muestran la relación entre recall (exhaustividad) y confidence (confianza) para un modelo de clasificación con 8 clases (A, MB, M, CP, RC, PU, MT, CG), más una curva agregada para todas las clases (línea azul gruesa).




Figura 59: Gráfico: Recall-Confidence Curve-150 época
Fuente: Imagen propia generada en Python

- El eje X representa la confianza (0 a 1), el eje Y representa el recall (0 a 1).
- A diferencia de las curvas de precisión, las curvas de recall tienden a descender a medida que aumenta el umbral de confianza.
- **Clase MT (rosa):** Mantiene el mejor rendimiento de recall, con una caída mínima hasta aproximadamente 0.8 de confianza.
- **Clases de alto rendimiento (MB, A):** Mantienen buen recall hasta umbrales de confianza altos.
- **Clases de rendimiento medio (M, CG, PU):** Muestran una degradación más gradual del recall.
- **Clases de bajo rendimiento (CP, RC):** Presentan los valores de recall más bajos, especialmente RC (púrpura) que cae con umbrales de confianza bajos.

■ 1.4. Análisis gráfico: Precision-Recall Curve

Las gráficas precision-Recall (PR) permiten evaluar modelos de clasificación,

especialmente útiles cuando hay desbalance de clases:




Figura 60: Gráfico-Precisión: Recall-Confidence Curve-150 épocas
Fuente: Imagen propia generada en Python

Rendimiento por clases:

- **Clases de alto rendimiento (MT, MB, A):**
 - Mantienen alta precisión incluso con valores de recall elevados.
 - MT tiene el mejor AP (0.976/0.975)
 - MB y A también muestran excelente rendimiento (>0.95)
 - **Clases de rendimiento medio (M, PU, CG)**
 - M muestra buen rendimiento (0.922/0.921)
 - PU mantiene un AP alrededor de 0.89
 - CG muestra un comportamiento intermedio
 - **Clases de bajo rendimiento (CP, RC):**
 - RC tiene el peor rendimiento en ambos modelos.
 - CP muestra rendimiento limitado pero mejor que RC.
- **1.5. Análisis de validación de etiquetas por lotes de YOLO**
Se muestran grids de 16 capturas (4x4). Las imágenes corresponden a detecciones y clasificaciones de vehículos mediante Yolo V.8.m.



Figura 61: Validación de etiquetas-150 épocas
Fuente: Imagen propia generada en Python

Características de detección:

- **Clases predominantes:**
 - Clase A (autos): Predominante, con cajas azules
 - Clase MB: Segunda más común, marcada en azul claro
 - Clase M: Abundante, especialmente en los laterales de la calle
- **Densidad de tráfico:**
 - Varía entre capturas, presentan variada congestión.
 - Se detectan vehículos en diferentes posiciones y orientaciones.
- **Confianza de detección:**
 - Múltiples detecciones en algunas áreas, sugiriendo diferentes niveles de confianza.

■ 1.6. Análisis de predicciones del lote de validación de YOLO

Se muestran grids de 16 capturas (4x4). A diferencia de las imágenes anteriores, estas incluyen valores numéricos que representan la puntuación de confianza de cada detección:



Figura 62: Validación de predicciones-150 épocas
Fuente: Imagen propia generada en Python

Características de las detecciones:

- **Distribución de confianza:**
 - Clase A (automóviles): Generalmente alta confianza (0.9-1.0).
 - Clase M (motocicletas): Confianza consistentemente alta (0.8-0.9)
 - Clase MB (microbuses): Confianza variable (0.5-1.0)
 - Clases menos comunes (RC, CG, PU): Confianza más variable.
- **Detecciones múltiples:**
 - Varios vehículos reciben múltiples etiquetas con diferentes niveles de confianza.
 - Las motos (M) frecuentemente se detectan con alta confianza (0.9)
- **Escenas representadas:**
 - Variedad de situaciones de tráfico y densidades de vehículos
 - Diferentes condiciones de iluminación y ángulos de visión

■ **1.7. Análisis de panel de métricas de entrenamiento y validación**

Estas gráficas muestran la evolución de diversos indicadores de rendimiento durante el entrenamiento de un modelo de detección de objetos, YOLOv8. Se presentan 10 gráficas organizadas en dos filas:




Figura 63: Métricas de entrenamiento y validación-150 épocas

Fuente: Imagen propia generada en Python

Características de las métricas:

- **Métricas de Entrenamiento:**
 - **train/box_loss:** Pérdida de localización de cajas delimitadoras durante el entrenamiento.
 - **train/cls_loss:** Pérdida de clasificación durante el entrenamiento.
 - **train/dfl_loss:** Pérdida de distribución focal (DFL) durante el entrenamiento.
- **Métricas de Validación:**
 - **val/box_loss:** Pérdida de localización de cajas delimitadoras en el conjunto de validación.

- **val/cls_loss**: Pérdida de clasificación en el conjunto de validación.
- **val/df_l_loss**: Pérdida de distribución focal (DFL) en el conjunto de validación.
- **Métricas de Evaluación (Conjunto B):**
 - **metrics/precision(B)**: Precisión en el conjunto B.
 - **metrics/recall(B)**: Recall en el conjunto B.
 - **metrics/mAP50(B)**: Mean Average Precision (mAP) con un umbral de Intersección sobre Unión (IoU) de 0.5 en el conjunto B.
 - **metrics/mAP50-95(B)**: Mean Average Precision (mAP) promediado en varios umbrales de Intersección sobre Unión (IoU) que van desde 0.5 hasta 0.95 en el conjunto B.
- **1.8. Resumen entrenamiento 150 épocas**
 - **Early Stopping**: El entrenamiento se detuvo temprano en la época 146 debido a que no se observó ninguna mejora en el modelo durante las últimas 20 épocas. Esto es una buena señal de que el proceso de entrenamiento está optimizado para evitar el sobreajuste.
 - **Mejor Época**: Los mejores resultados se observaron en la época 126, y el modelo correspondiente se guardó como best.pt. Modelo para la inferencia y detección de objetos.
 - **El mAP50 es 0.89**: Lo que indica que el modelo tiene un buen rendimiento en la detección de objetos cuando se utiliza un umbral de superposición de la Intersección sobre Unión (IoU) del 50 %.
 - **El mAP50-95:0.792**: Lo que proporciona una medida más completa del rendimiento del modelo en un rango de umbrales de IoU (del 50 % al 95 %).
 - **Precisión: 0.893** Cuando el modelo detecta un objeto, es correcto el 89.3 % de las veces.
 - **Recall:0.827** El modelo es capaz de encontrar el 82.7 % de todos los objetos reales en las imágenes.
 - **Velocidad de preprocesamiento**: 0.3ms por imagen
 - **Velocidad de inferencia**: 5.5ms por imagen. Este valor indica que el modelo es bastante rápido, con la inferencia tomando solo 5.5ms por imagen. Esto es importante para posteriores aplicaciones en tiempo real.
 - **Velocidad de Postprocesamiento**: 0.7ms por imagen.

Estos valores indican un buen equilibrio entre precisión y recall, lo que sugiere que el modelo es efectivo tanto en identificar objetos correctamente como en minimizar las detecciones incorrectas.

Cuadro 7: Resultados mAP50 y mAP50-95, 150 épocas

Clases Específicas	mAP50	mAP50-95
Clase A	0.955	0.84
Clase MB	0.966	0.856
Clase M	0.922	0.719
Clase CP	0.801	0.711
Clase RC	0.745	0.665
Clase PU	0.892	0.809
Clase MT	0.976	0.927
Clase CG	0.862	0.81

Fuente: Elaboración propia

Cuadro 8: Tiempos de Procesamiento-150 épocas.

Tiempos	Velocidad
Preprocesamiento	0.3ms por imagen
Inferencia	5.5ms por imagen
Postprocesamiento	0.7ms por imagen

Fuente: Elaboración propia

2. Entrenamiento 126 épocas

■ 2.1. Análisis multidimensional




Figura 64: Gráfica:Análisis multidimensional-126 épocas

Fuente: Imagen propia generada en Python

Comparativa del análisis multidimensional con el modelo de 150 épocas

- Las mismas distribuciones de barras para las categorías A, MB, M, CP, RC, PU, MT y CG. Los mismos patrones de rectángulos superpuestos en la esquina superior

derecha.

- Patrones de dispersión idénticos en los gráficos de x vs y. Distribuciones similares en el gráfico de width vs height.
- Esta similitud visual sugiere que la reducción en el número de épocas de entrenamiento (de 150 a 126) no produjo cambios significativos en los resultados visualizables del modelo. Esto indica que:
- El modelo ya había alcanzado una convergencia adecuada en 126 épocas. Las 24 épocas adicionales no aportaron mejoras sustanciales al rendimiento. Posiblemente el modelo esté alcanzando un punto de estabilidad donde más entrenamiento no resulta en cambios notables.

■ 2.2. Análisis gráfico: Precision-Confidence Curve




Figura 65: Gráfico: Precision-Confidence Curve-126 épocas
Fuente: Imagen propia generada en Python

- La clase MT muestra un rendimiento notablemente mejor en los niveles bajos y medios de confianza comparado con la gráfica de precisión (150 épocas).
- A diferencia de la gráfica de precisión, para 150 épocas, la curva MB está más separada de las clases A y M en la región de confianza media (0.2-0.5), mostrando mejor rendimiento.
- En la gráfica de precisión de 150 épocas, CG muestra más irregularidades y fluctuaciones, en la gráfica actual, aunque su rendimiento general sigue siendo el más bajo, la curva es más suave.
- A comparativa de la gráfica de 150 épocas, la gráfica actual muestra una mayor separación entre los grupos de rendimiento alto (MT, MB, A, M) y los de rendimiento bajo (CP, RC, PU, CG).

■ 2.3. Análisis gráfico: Recall-Confidence Curve




Figura 66: Gráfico-Recall-Confidence Curve-126 épocas
Fuente: Imagen propia generada en Python

- **Clase MB (Naranja):** MB muestra un mejor rendimiento, manteniendo valores de recall más altos a lo largo de diferentes umbrales de confianza en comparativa al modelo de entrenamiento con 150 épocas.
- **Clase CG (Gris):** Mantiene un recall ligeramente superior en valores de confianza entre 0.6-0.8. Muestra un comportamiento más estable, con menos fluctuaciones. En comparativa al modelo de entrenamiento con 150 épocas.
- **Clase CP (roja):** Muestra un comportamiento más constante entre los valores de confianza 0.2-0.6.
- **Comportamiento general:** La presente gráfica (126 épocas) muestra curvas más suaves y menos escalonadas para varias clases. Hay menos fluctuaciones abruptas, lo que sugiere mayor estabilidad en las predicciones.

■ 2.4. Análisis gráfico: Precision-Recall Curve




Figura 67: Gráfico-Precisión-Recall-Confidence Curve-126 épocas
Fuente: Imagen propia generada en Python

Rendimiento por clases

Se observa una clara estratificación del rendimiento:

- **Clases de alto rendimiento (MT, MB, A):**
 - Mantienen alta precisión incluso con valores de recall elevados.
 - MB y A también muestran excelente rendimiento (>0.95)
 - **Clases de rendimiento medio (M, PU, CG):**
 - M muestra buen rendimiento (0.922/0.921)
 - PU mantiene un AP alrededor de 0.89
 - CG muestra un comportamiento intermedio
 - **Clases de bajo rendimiento (CP, RC):**
 - RC tiene el peor rendimiento en ambos modelos
 - CP muestra rendimiento limitado pero mejor que RC
- **2.5. Análisis de validación de etiquetas por lotes de YOLO**



Figura 68: Validación de predicciones-126 épocas

Fuente: Imagen propia generada en Python

Comparativa con el entrenamiento de 150 épocas:

- **Secuencias temporales:**
 - Entrenamiento 150 épocas: Serie 1300 (1328, 1333, 1339, etc.)
 - Entrenamiento 126 épocas: Serie 1100-1200 (1192, 1193, 1194, etc.) Sugiere que son conjuntos de datos de diferentes momentos.
- **Consistencia de detección:**
 - Entrenamiento 150 épocas: Tiene más casos de múltiples etiquetas superpuestas para el mismo vehículo.
 - Entrenamiento 126 épocas: Muestra detecciones más consistentes y menos redundantes.
- **Precisión de las cajas delimitadoras:**
 - Entrenamiento 150 épocas: Muestra algunas cajas más grandes o imprecisas.

- Entrenamiento 126 épocas: Presenta cajas delimitadoras más ajustadas a los vehículos.
- **Clasificación de vehículos menos comunes:**
- Entrenamiento 150 épocas: Muestra más confusión entre clases similares.
- Entrenamiento 126 épocas: Tiene mejor detección de la clase PU (rosa).
- **Densidad de etiquetas:**
- Entrenamiento 150 épocas: Tiende a tener más etiquetas por vehículo.
- Entrenamiento 126 épocas: Más selectiva en sus predicciones).

El modelo entrenado con 126 épocas muestra un comportamiento más refinado y preciso en la detección y clasificación de vehículos. Las cajas delimitadoras están mejor ajustadas, hay menos redundancia en las detecciones y mayor consistencia en la clasificación. La evidencia visual confirma que reducir el número de épocas a 126 fue beneficioso, posiblemente evitando el sobreajuste y mejorando la generalización del modelo.

■ 2.6. Análisis de predicciones del lote de validación de YOLO



Figura 69: Contenido del archivo dataset.yamal
Fuente: Imagen propia generada en Python

Comparativa con el entrenamiento de 150 épocas:

- **Ajuste de confianza:**
- Entrenamiento 150 épocas: Tendencia a asignar valores de confianza más altos en general.
- Entrenamiento 126 épocas: Valores de confianza generalmente más bajos pero más precisos.
- **Especificidad de detección:**
- Tendencia a clasificar con alta confianza hacia las clases dominantes.
- Entrenamiento 126 épocas: Mayor probabilidad de identificar correctamente vehículos menos comunes (PU, CG, RC).
- **Calibración de confianza:**
- Entrenamiento 150 épocas: Muestra sobrevaloración de confianza en algunas

detecciones.

- Entrenamiento 126 épocas: Mejor correlación entre el valor de confianza y la precisión real de la detección.

El modelo entrenado con 126 épocas muestra una calibración de confianza más realista y precisa. Mientras que el modelo de 150 épocas tiende a “sobreconfiar” en sus predicciones (valores más cercanos a 1), el modelo de 126 épocas parece estar mejor calibrado, asignando valores de confianza más ajustados a la realidad de cada detección.

Este comportamiento confirma lo que observamos en las curvas de métricas anteriores, el modelo con menos épocas logra un mejor equilibrio, especialmente para las clases menos representadas, y evita el problema de sobreajuste que comienza a manifestarse con entrenamiento excesivo. La evidencia visual con los valores de confianza refuerza la conclusión de que 126 épocas proporcionan un punto óptimo de entrenamiento para este modelo específico.

■ 2.7. Análisis de panel de métricas de entrenamiento y validación




Figura 70: Métricas de entrenamiento y validación-150 épocas

Fuente: Imagen propia generada en Python

Comparativa con el entrenamiento de 150 épocas

- **Ajuste de confianza:**
 - Entrenamiento 150 épocas: Muestra algunas fluctuaciones más pronunciadas en las épocas finales, especialmente en metrics/precision(B) y metrics/recall(B)
 - Entrenamiento 126 épocas: Termina en un punto donde las métricas están más estables
- **Valores finales:**
 - Los valores finales de pérdida (box_loss, cls_loss, df_l_loss) son prácticamente idénticos

- Las métricas de precisión y recall alcanzan valores similares al final en ambos casos
- **Evolución de mAP:**
 - Entrenamiento 150 épocas: las curvas de mAP (tanto mAP50 como mAP50-95) muestran una ligera meseta en las épocas finales
 - Entrenamiento 126 épocas: Las curvas terminan justo cuando parecen alcanzar su punto de estabilización óptimo
- **Espacio de escala:**
 - Entrenamiento 150 épocas: Posee más puntos de datos, pero sigue el mismo patrón general
 - Entrenamiento 126 épocas: Captura la fase más crítica del aprendizaje.

Las gráficas confirman que el entrenamiento de 126 épocas alcanza un punto de rendimiento óptimo similar al de 150 épocas. Hacia la época 126, todas las métricas importantes (pérdidas, precisión, recall, mAP) ya han convergido sustancialmente.

El entrenamiento adicional (hasta 150 épocas) no aporta mejoras significativas y podría estar introduciendo ligeras fluctuaciones en algunas métricas. La gráfica de 126 épocas muestra que el modelo termina en un punto estable y óptimo de su curva de aprendizaje.

Esta evidencia adicional refuerza las conclusiones previas: 126 épocas proporcionan un equilibrio más eficiente entre rendimiento y costo computacional para este modelo específico.

■ 2.8. Resumen entrenamiento 126 epocas

- **Early Stopping:** Los resultados del entrenamiento del modelo YOLOv8 durante 126 épocas muestran un rendimiento sólido en la detección de objetos.
- **Mejor Época:** La época es el mejor modelo para la inferencia y detección de objetos.
- **El mAP50 es 0.892 y mAP50-95:0.792:** Indican un buen equilibrio entre precisión y recall, lo que sugiere que el modelo es efectivo tanto en identificar objetos correctamente como en detectar la mayoría de los objetos presentes.
- **Precisión: 0.887:** Cuando el modelo detecta un objeto, es correcto el 88.7% de las veces.
- **0.832 (validación) / 0.834 (evaluación):** Estos valores son indicativos de un modelo eficaz, capaz de identificar objetos con alta certeza y, al mismo tiempo, de detectar una proporción significativa de los objetos reales.
- **Velocidad de preprocesamiento:** 0.3ms por imagen
- **Velocidad de inferencia:** 5.5ms por imagen. Este valor indica que el modelo es bastante rápido, con la inferencia tomando solo 5.5ms por imagen. Esto es importante para posteriores aplicaciones en tiempo real.
- **Velocidad de Postprocesamiento:** 0.7ms por imagen.

Estos valores indican un buen equilibrio entre precisión y recall, lo que sugiere que el modelo es efectivo tanto en identificar objetos correctamente como en detectar la mayoría de los objetos presentes.

Cuadro 9: Resultados mAP50 y mAP50-95, 126 épocas

Clases Específicas	mAP50	mAP50-95
Clase A	0.954	0.836
Clase MB	0.964	0.852
Clase M	0.921	0.719
Clase CP	0.815	0.71
Clase RC	0.772	0.687
Clase PU	0.891	0.809
Clase MT	0.975	0.928
Clase CG	0.842	0.792

Fuente: Elaboración propia.

El cuadro de resultados mAP50 y mAP50-95, 126 épocas, muestra algunas variaciones, el modelo demuestra ser competente en la detección o clasificación de la mayoría de las clases.

Cuadro 10: Tiempos de Procesamiento-126 épocas.

Tiempos	Velocidad
Preprocesamiento	0.1 ms (validación) / 0.3 ms (evaluación)
Inferencia	2.6 ms (validación) / 4.7 ms (evaluación)
Postprocesamiento	0.9 ms (validación) / 1.0 ms (evaluación)

Fuente: Elaboración propia.

El cuadro de tiempos de procesamiento-126 épocas, indican que el modelo es extremadamente rápido, con la inferencia tomando solo 2.6 ms por imagen. Esto es sumamente importante para aplicaciones en tiempo real.

3. Comparativa de resultados 100, 126 y 150 épocas

Con el fin de facilitar la evaluación del impacto del número de épocas, se presentan cuadros comparativos de los resultados obtenidos en 100, 126 y 150 épocas.

Cuadro 11: Comparativa Precisión (P) , Recall (R), mAP50 , mAP50-95

Épocas	Precisión (P)	Recall (R)	mAP50	mAP50-95
100	0.885	0.84	0.887	0.793
126	0.887	0.832	0.892	0.792
150	0.892	0.828	0.89	0.791

Fuente: Elaboración propia

■ **Análisis comparativo: Precisión (P) Recall (R) mAP50 mAP50-95**

- El modelo de 100 épocas tiene el mejor recall (0.84), pero la precisión más baja.
- El modelo de 150 épocas muestra la mejor precisión (P) con 0.892, lo que indica que cuando predice una detección positiva, es más probable que sea correcta. Sin embargo, su recall (R) es el más bajo (0.828), lo que significa que detecta una proporción ligeramente menor de los objetos reales.
- El modelo entrenado durante 126 épocas presenta el mejor rendimiento general. Alcanza una precisión notable (0.887) y un recall aceptable (0.832), lo que sugiere un buen compromiso entre ambos. Además, logra el mAP50 más alto (0.892), la métrica clave para evaluar el rendimiento global del detector.

Cuadro 12: Comparativa tiempo de procesamiento

Épocas	Preprocesamiento	Inferencia	Postprocesamiento
100	0.1 ms	1.1 ms	0.9 ms
126	0.1 (val) / 0.3 (eval) ms	2.6 (val) / 4.7 (eval) ms	0.9 (val) / 1.0 (eval) ms
150	0.1 (val) / 0.3 (eval) ms	3.3 (val) / 5.5 (eval) ms	0.9 (val) / 0.7 (eval) ms

Fuente: Elaboración propia.

■ **Análisis comparativo:Preprocesamiento, Inferencia,Postprocesamiento:**

- El tiempo de preprocesamiento es consistente en todos los modelos (0.1 ms para validación y 0.3 ms para evaluación), lo cual es esperado ya que esta etapa suele ser independiente de la complejidad del modelo.
- El tiempo de inferencia aumenta significativamente con el número de épocas,el postprocesamiento se mantiene relativamente estable entre los modelos.
- Este incremento en el tiempo de inferencia sugiere que los modelos se vuelven más complejos o detallados con más épocas de entrenamiento.

■ **3.1. Elección del modelo de 126 épocas para la detección, clasificación y conteo.**

La métrica mAP50, alcanzó su valor máximo (0.892) con el modelo de 126 épocas en nuestra evaluación, es fundamental para garantizar la exactitud en la detección de

vehículos, un requisito primordial para el conteo vehicular confiable y la correcta asignación del valor UCP según la clase. Adicionalmente, la significativa reducción en el tiempo de inferencia en comparación con el modelo de 150 épocas es esencial para la predicción en tiempo real de las luces semafóricas, permitiendo ajustes oportunos basados en la demanda vehicular actual. Este equilibrio entre una alta precisión en la detección y una rápida capacidad de procesamiento convierte al modelo de 126 épocas en la solución más adecuada para las necesidades específicas de nuestro sistema de gestión de tráfico. A este modelo lo denominaremos *"bestfinal"*.

3.13.6. Análisis de la intersección semafórica del Jr. Carlos F. Vivanco y Jr. Sol

Se realizó una inspección directa del semáforo en la intersección de Jirón Carlos F. Vivanco y Jirón Sol, se llevó a cabo un análisis detallado de su funcionamiento. Esto incluyó la medición del tiempo que dura cada una de sus luces (ciclos semafóricos), la identificación de las direcciones en las que circulan los vehículos que regula, y la comprensión de cómo este semáforo específico organiza y dirige el movimiento del tráfico vehicular en ambas vías.

Esta inspección y análisis es fundamental, para plantear el modelo final, que determine y asigne la duración de las señales de tráfico en función de la densidad de vehículos.



Figura 71: Intersección semafórica-Jiron Carlos F. Vivanco y Jiron Sol
Fuente: Imagen propia



Figura 72: Intersección semafórica-Jiron Carlos F. Vivanco y Jiron Sol
Fuente: Imagen propia

Se determinó con precisión la duración de cada fase de la luz del semáforo (rojo, amarillo, verde) utilizando un cronómetro. Los datos recopilados se registraron en formatos de control específicos para ciclos semafóricos, los cuales se presentan con mayor detalle en la sección de anexos.

Cuadro 13: Tiempos y características de los ciclos semafóricos

Tiempo	Jr. Carlos F. Vivanco	Jr. Sol
Ambar	3	3
Rojo	45	55
Verde	50	40
Ciclo Total	98	98
Característica	Controla el flujo con mayor volumen vehicular	Maneja un volumen menor de tráfico

Fuente: Elaboración propia



Figura 73: Medición de los ciclos semafóricos-Jirón Carlos F. Vivanco con Jr. Sol
Fuente: Imagen propia

■ Fortalezas de la Configuración Actual

- **Ciclo sincronizado:** Ambos semáforos operan con un ciclo total idéntico de 98 segundos, facilitando la coordinación. La asignación de tiempo verde favorece a la vía con mayor demanda (51 % vs 41 % del ciclo), siguiendo principios básicos de ingeniería de tránsito. Los usuarios habituales pueden anticipar los cambios, lo que proporciona cierta estabilidad al sistema.

■ Problemas y limitaciones detectados

1. Inflexibilidad ante variaciones de demanda:

No responde a fluctuaciones del tráfico durante diferentes horas del día, mantiene tiempos fijos incluso cuando una dirección tiene poco o ningún tráfico. No puede extender fases verdes durante picos inesperados de demanda.

2. Parámetros técnicos cuestionables:

El ciclo de 98 segundos es relativamente largo, generando tiempos de espera excesivos. El tiempo ámbar de 3 segundos podría ser insuficiente.

3. Impacto negativo en la fluidez del tráfico:

Genera patrones ineficientes de "detención-arranque" (stop-and-go), aumentando innecesariamente los tiempos de viaje durante períodos de baja demanda ocasionando el incremento del consumo de combustible y emisiones por las detenciones frecuentes.

3.13.7. Detección, clasificación y conteo de vehículos

El modelo análisis de tráfico, utiliza YOLO V.8 (You Only Look Once) para detectar y clasificar diferentes tipos de vehículos en un video. Se detalla cómo funciona el proceso de detección, clasificación y conteo:

1. Modelo de detección YOLO

El núcleo del sistema es un modelo YOLO preentrenado personalizado (bestfinal.pt) que ha sido entrenado para detectar y clasificar 8 clases diferentes de vehículos.

- YOLO Divide la imagen en una cuadrícula.
- Por cada celda de la cuadrícula, predice: Bounding boxes (cajas delimitadoras), probabilidades de clase, niveles de confianza.
- Se utiliza un umbral de confianza de 0.6, para eliminar falsos positivos.

Python



```
# Inicializar modelo YOLO
model = YOLO(ruta_modelo)
conf_threshold = 0.6 # Umbral de confianza
model.conf = conf_threshold
```

Figura 74: Inicializar modelo YOLO
Fuente: Imagen propia

2. Proceso de detección

- El modelo YOLO analiza la imagen completa.
- Identifica potenciales bounding boxes donde podría haber vehículos el flujo de tráfico.
- Para cada bounding box, proporciona coordenadas (x1, y1, x2, y2), clase predicha (0-7), nivel de confianza (0.6-1.0)

Python



```
resultados = model.predict(frame, conf=conf_threshold, verbose=False)

for result in resultados:
    boxes = result.boxes
    for box in boxes:
        x1, y1, x2, y2 = map(int, box.xyxy[0]) # Coordenadas del bounding box
        cls = int(box.cls[0]) # Clase del vehículo
        conf = float(box.conf[0]) # Confianza de la detección
```

Figura 75: Determinación de los bounding boxes
Fuente: Imagen propia

3. Clases de vehículos y asignación del valor UCP

- El modelo clasifica los vehículos en 8 categorías, cada una con un valor UCP (Unidad de asignado).
- Estos valores UCP reflejan el impacto relativo de cada tipo de vehículo en el flujo de tráfico .

Python



```
ucp_por_clase = {
    0: 1.00, # A (Auto)
    1: 2.50, # MB
    2: 0.33, # M (Moto)
    3: 2.50, # CP
    4: 2.00, # RC
    5: 1.25, # PU
    6: 0.75, # MT
    7: 3.50 # CG
}
```

Figura 76: Asignación de valores UCP, para cada categoría (clase)
Fuente: Imagen propia

4. Filtrado temporal para reducir falsos positivos

- La función filtrar detecciones temporal, almacena las detecciones de varios frames consecutivos y solo considera válidas aquellas que aparecen de manera consistente durante múltiples frames. Esto reduce significativamente los falsos positivos.
- En el modelo, un vehículo debe aparecer en al menos 2 frames (por defecto) para ser considerado una detección válida.

Python



```
detecciones_filtradas = filtrar_detecciones_temporal(
    detecciones_frame,
    detecciones_historicas,
    frames_umbral=umbral_consistencia
)
```

Figura 77: Filtrado temporal para reducir falsos positivos

Fuente: Imagen propia

5. Tracking de vehículos para conteo único

- El modelo implementa un sistema de tracking básico para asignar IDs únicos a cada vehículo y evitar conteos duplicados.
- Esta técnica permite contar cada vehículo una sola vez a medida que se mueve por el campo de visión, en lugar de contarlos múltiples veces en cada frame. :
- La función asignar ID vehiculo, calcula el centro de la detección actual, busca si existe algún vehículo ya trackeado cerca de esa posición. Si lo encuentra, actualiza su posición y su clase (si la nueva detección tiene mayor confianza)

Python



```
vehiculo_id = asignar_id_vehiculo(cls, x1, y1, x2, y2, conf)
```

Figura 78: Función asignar ID vehículo

Fuente: Imagen propia

6. Mejora de clasificación mediante confianza

- El modelo presenta un sistema inteligente para mejorar la clasificación a lo largo del tiempo, esto se basa en que, detecta el mismo vehículo en múltiples frames y lo clasifica con mayor confianza.
- Este sistema mejora la precisión de la clasificación a lo largo del tiempo, especialmente cuando los vehículos están parcialmente ocluidos o en ángulos difíciles.


```

Python

if id_vehiculo in cls_confianza_ids and confianza > cls_confianza_ids[id_vehiculo]:
    # Si la clase es diferente, ajustar los contadores
    clase_anterior = cls_confianza_ids[id_vehiculo][0]
    if clase_anterior != clase:
        conteo_unico_por_clase[clase_anterior] -= 1
        ucp_total_por_clase[clase_anterior] -= ucp_por_clase.get(clase_anterior, 1)
        conteo_unico_por_clase[clase] += 1
        ucp_total_por_clase[clase] += ucp_por_clase.get(clase, 1.0)

    # Actualizar la clase y confianza para este ID
    cls_confianza_ids[id_vehiculo] = (clase, confianza)

```

Figura 79: Mejora de clasificación mediante confianza
Fuente: Imagen propia

7. Visualización de cada detección

- Para cada detección validada, el sistema dibuja, un bounding box con el color correspondiente a la clase.
- Una etiqueta con información sobre la clase, confianza, ID y valor UCP.
- La trayectoria del vehículo (si ha sido trackeado durante varios frames).

```

Python

# Dibujar bounding box
color = get_color(clase_mostrar)
cv2.rectangle(frame, (x1, y1), (x2, y2), color, 2)

# Dibujar trayectoria
if len(historico_ids[vehiculo_id]) > 1:
    for i in range(len(historico_ids[vehiculo_id])-1):
        pos1 = historico_ids[vehiculo_id][i]
        pos2 = historico_ids[vehiculo_id][i+1]
        linea_color = tuple([c//2 for c in color])
        cv2.line(frame, pos1, pos2, linea_color, 2)

```

Figura 80: Código de visualización
Fuente: Imagen propia




Figura 81: Detección, clasificación y conteo, realizado por el modelo
Fuente: Imagen propia

3.13.8. Predicción de ciclos semafóricos basado en demanda vehicular y densidad UCP

El núcleo del modelo de predicción semafórica se basa principalmente en dos variables críticas de la ingeniería de tránsito:

- **Demanda vehicular cuantificada:** Medida precisa del volumen total de tráfico que requiere servicio en la intersección, expresada como:
 - Número total de vehículos que atraviesan la intersección.
 - Composición específica del tráfico (proporción de cada tipo de vehículo)
 - Volumen total de UCP acumulado durante el periodo de observación.
- **Densidad UCP (Unidades de Coche Patrón):** Parámetro fundamental que representa la carga real del tráfico normalizada, calculada como:
 - UCP por unidad de tiempo (UCP/segundo)
 - UCP por unidad de longitud (UCP/km/h)
 - Relación con la capacidad vial ideal (grado de saturación)

Proceso de predicción de los ciclos semafóricos

1. Conteo vehicular

- El sistema detecta, clasifica y realiza un seguimiento de cada vehículo para evitar duplicados, cada vehículo detectado contribuye según su valor UCP específico.

```
Python

# Detección con YOLO
resultados = model.predict(frame, conf=conf_threshold, verbose=False)

# Procesar detecciones
detecciones_frame = []
for result in resultados:
    boxes = result.boxes
    for box in boxes:
        x1, y1, x2, y2 = map(int, box.xyxy[0])
        cls = int(box.cls[0])
        conf = float(box.conf[0])

        # Guardar para análisis
        detecciones_frame.append([x1, y1, x2, y2, cls, conf])

# Filtrado temporal para reducir falsos positivos
detecciones_filtradas = filtrar_detecciones_temporal(
    detecciones_frame,
    detecciones_historicas,
    frames_umbral=umbral_consistencia
)
```

Figura 82: Detecciones y filtrado temporal

Fuente: Imagen propia

2. Contabilización de demanda total

- Suma ponderada según valores UCP específicos para cada clase del total de vehículos únicos detectados, se obtiene la “demanda total UCP”

- Densidad UCP = UCP Total / duración de observación, este valor representa la cantidad de vehículos equivalentes por unidad de tiempo.

```
Python
# Cálculos finales
total_ucp = sum(ucp_total_por_clase.values())
total_vehiculos = len(vehiculos_unicos)
```

Figura 83: Contabilización de demanda total

Fuente: Imagen propia

3. Normalización a estándares de ingeniería

- Densidad UCP/km/h = Densidad UCP × 3600 / 1000 Conversión a unidades estándar para aplicación de criterios técnicos.
- Estos valores UCP reflejan el impacto relativo de cada tipo de vehículo en el flujo de tráfico .

```
Python
# Convertir a densidad por kilómetro
densidad_ucp_km = densidad_ucp * 3600 / 1000 # UCP/km/h
```

Figura 84: Medición de los ciclos semafóricos-Jr. Sol con el Jirón Carlos F. Vivanco

Fuente: Imagen propia

4. Determinación del grado de saturación:

- Grado de Saturación = Densidad UCP / Capacidad Ideal

```
Python
# Capacidad ideal estimada
capacidad_ideal_segundo = 1900 / 3600 # UCP/segundo/carril

# Grado de saturación
grado_saturacion = min(1.0, densidad_ucp / capacidad_ideal_segundo)
```

Figura 85: Determinación del grado de saturación

Fuente: Imagen propia

5. Determinación del tiempo verde base

- El tiempo verde mínimo se establece exclusivamente en función de la demanda UCP total:

```
Python
# Ajuste del tiempo verde base según UCP total
if ucp_total > 20:
    tiempo_verde_base = 18.0
elif ucp_total > 10:
    tiempo_verde_base = 16.0
else:
    tiempo_verde_base = 15.0
```

Figura 86: Determinación del tiempo verde base

Fuente: Imagen propia

6. Incremento proporcional basado en densidad

- El incremento adicional se determina exclusivamente según el grado de saturación derivado de la densidad UCP.

Python



```
# Incremento adicional con escala progresiva
if grado_saturacion > 0.8:
    incremento_adicional = 1.0 + (0.25 * grado_saturacion) # Hasta 25% extra
elif grado_saturacion > 0.5:
    incremento_adicional = 1.0 + (0.20 * grado_saturacion) # Hasta 20% extra
else:
    incremento_adicional = 1.0 + (0.18 * grado_saturacion) # Hasta 18% extra
```

Figura 87: Incremento proporcional basado en densidad
Fuente: Imagen propia

7. Factor de escala por demanda total

- Se aplica un factor multiplicador basado directamente en la demanda UCP total: $\text{Factor} = \min(1.20, \max(1.0, \text{UCP Total}/25))$. Este factor reconoce explícitamente que intersecciones con mayor demanda requieren ciclos proporcionalmente más largos.

Python



```
# Factor de escalamiento directo basado en UCP total
factor_escal_ucp = min(1.20, max(1.0, ucp_total / 25)) # Suavizado a 1.0-1.20x
```

Figura 88: Factor de escala por demanda total
Fuente: Imagen propia

8. Cálculo del tiempo verde final

- El tiempo verde se limita entre el tiempo verde base y un máximo de 60 segundos. Para el semáforo 1 se calcula combinando todos estos factores:

Python



```
tiempo_verde_sem1 = tiempo_verde_base + (factor_webster * factor_ajuste * factor_e
tiempo_verde_sem1 = tiempo_verde_sem1 * incremento_adicional
```

Figura 89: Cálculo del tiempo verde final
Fuente: Imagen propia

9. Cálculo del tiempo ambar

- El tiempo ámbar se ajusta según la densidad del tráfico:

Python



```
tiempo_ambar_base = 3.0
ajuste_densidad = np.sqrt(grado_saturacion) * 1.2
tiempo_ambar_sem1 = tiempo_ambar_base + min(2.0, ajuste_densidad)
tiempo_ambar_sem1 = max(3.0, min(5.0, tiempo_ambar_sem1))
```

Figura 90: Cálculo del tiempo ambar

Fuente: Imagen propia

10. Cálculo de los ciclos-semáforo 2

- El cálculo para el tiempo en rojo y ambar para el semáforo 2:

Python



```
tiempo_despeje = 1.0 # Tiempo de seguridad entre cambios
tiempo_rojo_sem2 = tiempo_verde_sem1 + tiempo_ambar_sem1 + tiempo_despeje
tiempo_ambar_sem2 = tiempo_ambar_sem1
```

Figura 91: Cálculo de los ciclos-semáforo 2

Fuente: Imagen propia

11. Determinación del ciclo total

- El ciclo semafórico completo se calcula como:

Python



```
ciclo_total = tiempo_verde_sem1 + tiempo_ambar_sem1 + tiempo_despeje
```

Figura 92: Determinación del ciclo total

Fuente: Imagen propia

12. Evaluación del nivel de servicio

- Se determina el nivel de servicio (A-F) basado en la densidad UCP:

Python



```
if ucp_total < 9:
    return "A", "Flujo libre", "green"
elif ucp_total < 14:
    return "B", "Flujo estable razonable", "lightgreen"
# etc.
```

Figura 93: Evaluación del nivel de servicio

Fuente: Imagen propia

4. RESULTADOS

4.1. Contrastación de hipótesis

4.1.1. Contrastación de hipótesis específica 1

- El diseño del modelo basado en Redes Neuronales Artificiales (RNA) permite ajustar una arquitectura, para la detección, clasificación y conteo eficiente de vehículos, en condiciones heterogéneas, que incluyen tráfico variable, diversas condiciones ambientales (precipitaciones, iluminación solar variable, sombras proyectadas) y entornos nocturnos con visibilidad limitada.

Se diseñó una arquitectura basada en YOLO (You Only Look Once) específicamente ajustada para la detección vehicular de alta precisión, presentando las siguientes características:

Arquitectura del modelo

1. Modelo YOLO personalizado

- Se implementó un modelo con pesos específicamente entrenados (bestfinal.pt) para reconocer 8 categorías de vehículos bajo condiciones heterogéneas.

2. Configuración de parámetros optimizados

- Adaptación de la red neuronal para maximizar rendimiento en entornos urbanos con alta densidad vehicular.
- Umbral de confianza (0.6) calibrado para equilibrar precisión y sensibilidad.

3. Sistema de filtrado temporal avanzado

- Implementación de ventana de validación (frames-umbral).
- Registro histórico de detecciones recientes (detecciones-historicas).
- Validación por consistencia temporal para discriminar entre objetos reales y artefactos ambientales.

4. Algoritmo de seguimiento robusto:

- Asignación de identificadores únicos con persistencia entre frames.
- Umbral de distancia adaptativo para mantener identidad en condiciones variables.
- Conservación de la clase con mayor confianza para cada vehículo detectado.
- Actualización de posición con criterios de proximidad espacial.

5. Visualización de trayectorias:

- Histórico de posiciones con longitud limitada para cada vehículo.
- Representación gráfica de movimiento para validación visual.
- Sistema de colores diferenciado por tipo de vehículo para seguimiento intuitivo.

Capacidades del modelo para condiciones heterogéneas

1. Variabilidad de tráfico

- Adaptación a diferentes densidades vehiculares.
- Precisión en la detección y clasificación con composición mixta de tipos de vehículos, eficacia en diferentes patrones de movimiento y velocidades.



Figura 94: Adaptación a tráfico ligero-velocidad alta de vehículos
Fuente: Imagen propia



Figura 95: Adaptación a tráfico medio-velocidad estandar de vehiculos
Fuente: Imagen propia




Figura 96: Adaptación a tráfico pesado-velocidad baja de vehículos
Fuente: Imagen propia

2. Condiciones ambientales adversas

- Filtrado de detecciones causadas por precipitaciones, cuando existe precipitación, las luces de los autos se refleja en el pavimento mojado, creando patrones de brillo que pueden confundir al modelo.




Figura 97: Deslumbramiento causado por las luces de los autos-lluvia intensa
Fuente: Imagen propia




Figura 98: Deslumbramiento causado por las luces de los autos-lluvia media
Fuente: Imagen propia




Figura 99: Deslumbramiento causado por las luces de los autos-lluvia tenue
Fuente: Imagen propia

- Compensación ante cambios de iluminación solar variable, mantenimiento el tracking continuo durante transiciones de iluminación, discriminación entre vehículos y sombras proyectadas.




Figura 100: Detección y conteo de vehículos bajo condiciones de sombras 11:20 am
Fuente: Imagen propia



Figura 101: Detección y conteo de vehículos bajo condiciones de sombras 14:55 pm
Fuente: Imagen propia

3. Entornos de visibilidad reducida-oclusión

- En espacios reducidos, los vehículos de menor tamaño frecuentemente quedan parcial o totalmente ocultos detrás de otros más grandes, dificultando su detección inmediata. Mediante el uso de un sistema de seguimiento temporal que asigna códigos de identificación únicos a cada vehículo detectado, podemos mantener un registro de su presencia incluso cuando temporalmente desaparecen del campo visual.



Figura 102: Seguimiento de vehículos detectado 09:06:28 am
Fuente: Imagen propia




Figura 103: Vehículo a punto de ocluirse por el microbus 09:06:30 am
Fuente: Imagen propia



Figura 104: Vehículo ocluido por el microbus pero registrado en el conteo 09:06:31 am
Fuente: Imagen propia

Resultados detección, clasificación y conteo vehicular en variable condición




Figura 105: Grab 01-Tráfico ligero-05:44 am-amanecer nublado
Fuente: Imagen propia



Figura 106: Grab 02-Tráfico ligero-06:21 am-mañana nublada
Fuente: Imagen propia




Figura 107: Grab 03-Tráfico ligero-06:31 am-mañana nublada
Fuente: Imagen propia




Figura 108: Grab 04-Tráfico pesado-07:48 am-mañana nublada
 Fuente: Imagen propia



Figura 109: Grab 05-Tráfico ligero-09:07 am-mañana soleada
 Fuente: Imagen propia




Figura 110: Grab 06-Tráfico pesado-10:53 am-media mañana nublada
 Fuente: Imagen propia



Figura 111: Grab 07-Tráfico pesado-11:14 am-media mañana soleada
 Fuente: Imagen propia



Figura 112: Grab 08-Tráfico medio-11:20 am-media mañana soleada con sombras
 Fuente: Imagen propia



Figura 113: Grab 09-Tráfico pesado-12:29 pm-medio día nublado
 Fuente: Imagen propia



Figura 114: Grab 10-Tráfico pesado-12:44 pm-medio día nublado
Fuente: Imagen propia




Figura 115: Grab 11-Tráfico ligero-14:56 pm-tarde soleada con sombras
Fuente: Imagen propia



Figura 116: Grab 12-Tráfico pesado-15:56 pm-tarde soleada con sombras
Fuente: Imagen propia




Figura 117: Grab 13-Tráfico pesado-16:21 pm-tarde soleada con sombras
Fuente: Imagen propia



Figura 118: Grab 14-Tráfico medio-17:04 pm-atarde nublado
Fuente: Imagen propia




Figura 119: Grab 15-Tráfico pesado-17:51 pm-atarde nublado
Fuente: Imagen propia




Figura 120: Grab 16-Tráfico ligero-18:32 pm-anocheecer
 Fuente: Imagen propia




Figura 121: Grab 17-Tráfico pesado-18:33 pm-anocheecer
 Fuente: Imagen propia




Figura 122: Grab 18-Tráfico ligero-18:48 pm-noche
 Fuente: Imagen propia




Figura 123: Grab 19-Tráfico pesado-18:51 pm-noche.
Fuente: Imagen propia




Figura 124: Grab 20-Tráfico pesado-18:56 pm-noche.
Fuente: Imagen propia




Figura 125: Grab 21-Tráfico pesado-19:52 pm-noche.
Fuente: Imagen propia




Figura 126: Grab 22-T.pesado-19:55 pm-lluvia intensa, viento y deslumbramiento.
 Fuente: Imagen propia



Figura 127: Grab 23-Tráfico pesado-19:57 pm-noche lluvia intensa y deslumbramiento
 Fuente: Imagen propia




Figura 128: Grab 24-Tráfico medio-20:18 pm-noche lluvia tenue y deslumbramiento
 Fuente: Imagen propia




Figura 129: Grab 25-Tráfico medio-20:28 pm-noche lluvia tenue y deslumbramiento
Fuente: Imagen propia




Figura 130: Grab 26-Tráfico medio-20:31 pm-noche lluvia tenue y deslumbramiento
Fuente: Imagen propia



Figura 131: Grab 27-Tráfico ligero-20:33 pm-noche lluvia tenue y deslumbramiento
Fuente: Imagen propia




Figura 132: Grab 28-Tráfico ligero-20:34 pm-noche lluvia tenue y deslumbramiento
Fuente: Imagen propia




Figura 133: Grab 29-Tráfico pesado-21:05 pm-noche lluvia tenue y deslumbramiento
Fuente: Imagen propia




Figura 134: Grab 30-Tráfico pesado-21:09 pm-noche lluvia tenue y deslumbramiento
Fuente: Imagen propia



Figura 135: Grab 31-Tráfico ligero-22:02 pm-noche
Fuente: Imagen propia




Figura 136: Grab 32-Tráfico pesado-22:48 pm-noche lluvia tenue y deslumbramiento
Fuente: Imagen propia

Cuadro 14: Resultados de detección, clasificación y conteo de vehículos en variable condición

Grab.	Hora	Característica	Detección/clasificación	Total
1	05:44 AM	Amanecer nublado	A:7, MB:1, M:1, PU:2, MT:1	12
2	06:21 AM	Nublado	A:5, MB:3, M:2, MT:1	11
3	06:31 AM	Nublado	A:5, MB:1, M:3	9
4	07:48 AM	Nublado	A:8, MB:4, M:4, CP:1, PU:1	18
5	09:07 AM	Soleado	A:4, MB:1, M:3, PU:1	9
6	10:53 AM	Media mañana	A:8, MB:6, M:2	16
7	11:14 AM	Media mañana	A:8, MB:7, M:6	21
8	11:21 AM	Soleado-sombras	A:7, MB:4, M:6, PU:1, CG:1	19
9	12:29 PM	Mediodía	A:4, MB:6, M:4, CP:1, PU:3	18
10	12:44 PM	Nublado	A:10, MB:5, M:5, PU:1	21
11	14:56 PM	Soleado-sombras	A:7, MB:2, M:10	19
12	15:57 PM	Soleado-sombras	A:7, MB:4, M:2, CP:1, PU:3, CG:1	18
13	16:21 PM	Atardecer	A:10, MB:5, CP:1, PU:1	17
14	17:17 PM	Atardecer	A:3, MB:3, M:8, CP:1, CG:1	16
15	17:51 PM	Atardecer	A:8, MB:7, M:7, PU:1	23
16	18:32 PM	Anocheecer	A:4, MB:1, M:7, PU:1	13
17	18:33 PM	Anocheecer	A:7, MB:5, M:6, RC:1, PU:1	20
18	18:48 PM	Noche	A:3, MB:1, M:8	12
19	18:51 PM	Noche	A:12, MB:3, M:3	18
20	18:56 PM	Noche	A:6, MB:2, M:14, PU:2	24
21	19:52 PM	Noche	A:6, MB:3, M:9, RC:1, PU:1, CG:3	23
22	19:55 PM	Lluvia intensa/viento	A:7, MB:3, M:6, PU:3	19
23	19:57 PM	Lluvia intensa	A:10, MB:2, M:9, PU:1, MT:1	23
24	20:18 PM	Lluvia tenue	A:8, MB:1, M:9	18
25	20:28 PM	Lluvia tenue	A:9, MB:1, M:1, CP:1	12
26	20:31 PM	Lluvia tenue	A:6, M:6, PU:1	13
27	20:33 PM	Lluvia tenue	A:2, MB:1, M:4	7
28	20:34 PM	Lluvia tenue	A:9, M:6	15
29	21:05 PM	Lluvia tenue	A:7, MB:2, M:8, PU:3	20
30	21:09 PM	Lluvia tenue	A:5, M:9, RC:1, PU:1	16
31	22:02 PM	Noche	A:6, MB:8	14
32	22:48 PM	Lluvia tenue	A:10, M:2	12

Fuente: Elaboración propia

Análisis de resultados del sistema de detección y clasificación de vehículos

• Capacidad de manejo de volumen variable

- El sistema demuestra adaptabilidad a diferentes volúmenes de tráfico:
 - ◊ **Bajo volumen:** En la grabación 27 se detectaron 7 vehículos.
 - ◊ **Volumen medio:** La mayoría de las grabaciones se sitúan entre 12-19 vehículos.
 - ◊ **Alto volumen:** En las grabaciones 7, 10, 15, 20, 21 y 23 se superan los 20 vehículos detectados, alcanzando un máximo de 24 en la grabación 20.

• Rendimiento a lo largo del día

- El análisis temporal muestra un funcionamiento consistente durante las 24 horas:
 - ◊ **Madrugada/Amanecer:** (05:44-07:48 AM): Detección promedio de 12.5 vehículos.
 - ◊ **Mañana:** (09:07-12:29 PM): Detección promedio de 16.6 vehículos.
 - ◊ **Tarde:** (12:44-18:33 PM): Detección promedio de 18.5 vehículos.
 - ◊ **Noche:** (18:48-22:48 PM): Detección promedio de 16.9 vehículos.

• Consistencia en diversas condiciones ambientales

- El sistema muestra una notable consistencia en la detección de vehículos bajo múltiples condiciones ambientales:
 - ◊ **Amanecer:** En la grabación 1, el sistema identificó correctamente 12 vehículos, con una variedad de tipos (A:7, MB:1, M:1, PU:2, MT:1).
 - ◊ **Condiciones de nublado:** En las grabaciones 2, 3, 4 y 10, el sistema mantuvo una detección consistente con conteos de 11, 9, 18 y 21 vehículos respectivamente, demostrando estabilidad ante la baja luminosidad.
 - ◊ **Condiciones soleadas y sombras:** La grabación 5 refleja un correcto funcionamiento con 9 vehículos en condiciones de alto contraste lumínico. Las grabaciones 8, 10 y 11 reflejan un correcto funcionamiento en condiciones de sombras con 19, 19 y 18 vehículos respectivamente.
 - ◊ **Atardecer:** Las grabaciones 13-15 muestran detecciones precisas durante el cambio de luminosidad del atardecer, con 17, 16 y 23 vehículos respectivamente.
 - ◊ **Noche:** En condiciones nocturnas (grabaciones 18-21), el sistema alcanza detecciones notables, llegando a identificar hasta 24 vehículos en la grabación 20.
 - ◊ **Condiciones de Lluvia:** Lluvia intensa (grabaciones 22-23): Promedio de 21 vehículos detectados, lluvia tenue (grabaciones 24-30): Promedio de 14.4 vehículos detectados.

4.1.2. Contratación de hipótesis específica 2

- El entrenamiento del modelo, basado en Redes Neuronales Artificiales (RNA), logra un equilibrio óptimo entre la precisión en la detección, la exhaustividad en el reconocimiento de vehículos y la robustez contra el sobreajuste.

Se realizó el proceso de entrenamiento, con diversas configuraciones de épocas (1, 20, 50, 100, 126 y 150), con el objetivo de encontrar el punto de equilibrio óptimo entre precisión y exhaustividad, evitando el fenómeno de sobreajuste. La época 126 fue seleccionada como punto óptimo gracias a la implementación del mecanismo de Early Stopping, que señaló el momento ideal para detener el proceso de aprendizaje. Esta selección garantiza el balance adecuado entre los parámetros de precisión y exhaustividad que se perseguían como objetivo principal. La descripción detallada del entrenamiento con 126 épocas se detalla a continuación:

Entrenamiento 126 épocas

- **Análisis gráfico: Gráfico de barras**




Figura 137: Gráfico de barras-126 épocas
Fuente: Imagen propia generada en Python

Cuadro 15: Distribución de instancias por categoría de vehículo

Categoría	Número de instancias
A (Autos)	Aproximadamente 15,000
M (Motocicletas)	Cerca de 12,500
MB (Microbus)	Alrededor de 4,400
PU (Camionetas)	Aproximadamente 1,800
MT (Mototaxi/Motocargas)	Cerca de 1,000
CP (Camión Pequeño)	Menos de 500
RC (Rural Combi)	Menos de 500
CG (Camión Grande)	Menos de 500

Fuente: Elaboración propia

- **Características de la distribución:** Esta distribución sugiere una clasificación natural del fenómeno estudiado (vehículos que transitan por el Jirón Carlos F. Vivanco) donde ciertas categorías son intrínsecamente más comunes.
 - **Clases de alta frecuencia (A, M):** Los autos (aproximadamente 15,000 instancias) y motocicletas (cerca de 12,500 instancias) son los vehículos más comunes en la vía estudiada, constituyendo la mayoría del tráfico.
 - **Clases de frecuencia media (MB, PU):** Los microbuses (alrededor de 4,400 instancias) y camionetas (aproximadamente 1,800 instancias) representan una proporción significativa pero menor del tráfico.
 - **Clases de baja frecuencia (MT, CP, RC, CG):** Los mototaxis/motocargas (cerca de 1,000 instancias) y los vehículos de carga (camiones pequeños, camiones grandes), rurales combi y con menos de 500 instancias) son relativamente no frecuentes en la vía estudiada.
- **Análisis gráfico: Clustering o agrupamiento jerárquico**




Figura 138: Gráfico clustering o agrupamiento jerárquico-126 épocas

Fuente: Imagen propia generada en Python

- **Visualización:** Esta visualización muestra múltiples rectángulos superpuestos, el algoritmo está enfocando su atención, indicando zonas de alta densidad de características con patrones relevantes de diferentes tamaños y colores.
- **Zonas de alta densidad:** Las áreas con mayor concentración de rectángulos revelan regiones de la imagen donde el modelo detecta características visuales cruciales para la clasificación vehicular.
- **Patrones de diferentes tamaños:** La variedad de tamaños en los rectángulos refleja la capacidad del modelo para identificar vehículos a diferentes escalas y distancias de la cámara.
- **Codificación por colores:** Los diferentes colores representan distintas capas de abstracción en el proceso de detección, desde características de bajo nivel hasta patrones complejos específicos de cada clase vehicular.

• **Análisis gráfico: Mapa de calor X-Y**




Figura 139: Gráfico mapa de calor X-Y-126 épocas

Fuente: Imagen propia generada en Python

- **Característica** Evidencia la distribución conjunta de dos variables (x,y) en el rango [0,1]. La mayor densidad (azul más oscuro) se concentra cerca del origen (0,0). Existe un patrón vertical alrededor de $x \approx 0.4$ que muestra mayor intensidad.
- **Concentración cerca del origen:** La mayor densidad (azul más oscuro) se encuentra cerca del punto (0,0), indicando una tendencia de los vehículos a aparecer en áreas específicas del campo visual.
- **Patrón vertical distintivo:** El incremento de intensidad alrededor de $x \approx 0.4$ sugiere un carril o zona de tránsito preferente, posiblemente relacionado con la configuración vial del Jirón Carlos F. Vivanco.
- **Gradiente de intensidad:** La disminución progresiva de la intensidad hacia las áreas periféricas refleja la menor frecuencia de vehículos en estas zonas, probablemente correspondientes a aceras o áreas peatonales.

• **Análisis gráfico: Mapa de calor Width-Height**




Figura 140: Gráfico mapa de calor Width-Height-126 épocas

Fuente: Imagen propia generada en Python

- **Características:** Existe una correlación positiva clara: a mayor ancho, mayor altura. La mayor concentración está en valores pequeños (cerca del origen). La distribución se estrecha a medida que aumentan los valores.
 - **Correlación positiva clara:** Existe una relación directa entre ancho y alto, donde la mayoría de los vehículos mantienen proporciones relativamente constantes (relación de aspecto).
 - **Mayor concentración en valores pequeños:** La densidad más alta cerca del origen indica predominancia de vehículos de dimensiones reducidas en el dataset, consistente con la alta frecuencia de autos y motocicletas.
 - **Distribución afinada con el aumento de valores:** La disminución de frecuencia para dimensiones mayores corresponde a la menor presencia de vehículos grandes como camiones y buses.
 - **Pocos objetos de dimensiones extremas:** La baja densidad en zonas de valores altos de width/height confirma la escasez de vehículos muy grandes o con proporciones inusuales, explicando en parte el rendimiento limitado del modelo en clases como CG.
- **Análisis gráfico: Precision-Confidence Curve**




Figura 141: Gráfico: Precision-Confidence Curve-126 épocas

Fuente: Imagen propia generada en Python

- **Características** Se visualiza cómo varía la precisión del modelo a medida que ajustamos el umbral de confianza para cada una de las clases.
- **Clases de alto rendimiento (MT, MB, A):** Alcanzan precisión superior a 0.8 incluso con niveles bajos de confianza, estas clases tienen características muy distintivas que facilitan su detección.
- **Clases de rendimiento medio (M):** Alcanza buena precisión pero requiere un umbral de confianza ligeramente mayor.
- **Clases de regular rendimiento (CP, PU, RC, CG):** Tienen un número significativamente menor de instancias en comparación con clases como A, MB y M. Este desequilibrio afecta el aprendizaje del modelo, estas

clases con menor rendimiento presentan mayor variabilidad en sus características visuales, dificultando que el modelo identifique ciertos patrones consistentes.

• **Análisis gráfico: Recall-Confidence Curve**




Figura 142: Gráfico-Recall-Confidence Curve-126 épocas

Fuente: Imagen propia generada en Python

- **Característica** Evidencian la relación entre recall (exhaustividad) y confidence (confianza) para el modelo de clasificación con 8 clases (A, MB, M, CP, RC, PU, MT, CG), más una curva agregada para todas las clases (línea azul gruesa).
- **Clases de alto rendimiento (MT, MB, A):** Mantienen buen recall hasta umbrales de confianza altos.
- **Clases de rendimiento medio (M, CG, PU):** Muestran una degradación más gradual del recall.
- **Clases de bajo rendimiento (CP, RC):** Presentan los valores de recall más bajos, especialmente RC (púrpura) que cae con umbrales de confianza bajos.

• **Análisis gráfico: Precision-Recall Curve**




Figura 143: Gráfico-Precisión-Recall-Confidence Curve-126 épocas

Fuente: Imagen propia generada en Python

- **Clases de alto rendimiento (MT, MB, A):**
 - ◊ Mantienen alta precisión incluso con valores de recall elevados. MB, MT

y A también muestran excelente rendimiento (>0.95)

- **Clases de rendimiento medio (M, PU, CG):**

- ◊ M muestra buen rendimiento (0.922/0.921)
- ◊ PU mantiene un AP alrededor de 0.89
- ◊ CG muestra un comportamiento intermedio

- **Clases de bajo rendimiento (CP, RC):**

- ◊ RC muestra un rendimiento limitado.
- ◊ CP muestra rendimiento limitado pero mejor que RC.

- **Análisis de panel de métricas de entrenamiento y validación**




Figura 144: Métricas de entrenamiento y validación-150 épocas

Fuente: Imagen propia generada en Python

- **Ajuste de confianza:**

- ◊ Se evidencian algunas fluctuaciones más pronunciadas en las épocas finales, especialmente en metrics/precision(B) y metrics/recall(B). El entrenamiento 126 épocas, termina en un punto donde las métricas están más estables

- **Evolución de mAP:**

- ◊ Las curvas terminan justo cuando alcanzan su punto de estabilización óptimo.

- **Espacio de escala:**

- ◊ Entrenamiento 126 épocas: Captura la fase más crítica del aprendizaje.

- **Resumen entrenamiento 126 épocas**

- **Early Stopping:** Los resultados del entrenamiento del modelo YOLOv8 durante 126 épocas muestran un rendimiento sólido en la detección de objetos.
- **Mejor Época:** La época 126 es el mejor modelo para la inferencia y detección de objetos.
- **El mAP50 es 0.892 y mAP50-95: 0.792:** Indican un buen equilibrio entre

precisión y recall, lo que sugiere que el modelo es efectivo tanto en identificar objetos correctamente como en detectar la mayoría de los objetos presentes.

- **Precisión: 0.887:** Cuando el modelo detecta un objeto, es correcto el 88.7 % de las veces.
- **Recall: 0.832 (validación) / 0.834 (evaluación):** Estos valores son indicativos de un modelo eficaz, capaz de identificar objetos con alta certeza y, al mismo tiempo, de detectar una proporción significativa de los objetos reales.
- **Velocidad de preprocesamiento:** 0.3ms por imagen
- **Velocidad de inferencia:** 5.5ms por imagen. Este valor indica que el modelo es bastante rápido, con la inferencia tomando solo 5.5ms por imagen. Esto es importante para posteriores aplicaciones en tiempo real.
- **Velocidad de Postprocesamiento:** 0.7ms por imagen.

Estos valores indican un buen equilibrio entre precisión y recall, lo que sugiere que el modelo es efectivo tanto en identificar objetos correctamente como en detectar la mayoría de los objetos presentes.

Cuadro 16: Resultados mAP50 y mAP50-95, 126 épocas

Clases Específicas	mAP50	mAP50-95
Clase A	0.954	0.836
Clase MB	0.964	0.852
Clase M	0.921	0.719
Clase CP	0.815	0.71
Clase RC	0.772	0.687
Clase PU	0.891	0.809
Clase MT	0.975	0.928
Clase CG	0.842	0.792

Fuente: Elaboración propia

Cuadro 17: Tiempos de Procesamiento-126 épocas

Tiempos	Velocidad
Preprocesamiento	0.1 ms (validación) / 0.3 ms (evaluación)
Inferencia	2.6 ms (validación) / 4.7 ms (evaluación)
Postprocesamiento	0.9 ms (validación) / 1.0 ms (evaluación)

Fuente: Elaboración propia

Análisis de resultados del modelo de 126 épocas, en el equilibrio entre la precisión y exhaustividad evitando el sobreajuste

El modelo entrenado con 126 épocas muestra un comportamiento más refinado y preciso en la detección y clasificación de vehículos. Las cajas delimitadoras están mejor ajustadas, hay menos redundancia en las detecciones y mayor consistencia en la clasificación. La evidencia visual confirma que reducir el número de épocas a 126 fue beneficioso, evitando el sobreajuste y mejorando la generalización del modelo.

El modelo entrenado con 126 épocas muestra una calibración de confianza más realista y precisa. Mientras que el modelo de 150 épocas tiende a "sobreconfiar" en sus predicciones (valores más cercanos a 1), el modelo de 126 está mejor calibrado, asignando valores de confianza más ajustados a la realidad de cada detección.

La métrica mAP50, alcanzó su valor máximo (0.892) con el modelo de 126 épocas en nuestra evaluación, es fundamental para garantizar la exactitud en la detección de vehículos, un requisito primordial para el conteo vehicular confiable y la correcta asignación del valor UCP según la clase. El cuadro de tiempos de procesamiento-126 épocas, indican que el modelo es extremadamente rápido, con la inferencia tomando solo 2.6 ms por imagen. Esto es sumamente importante para aplicaciones en tiempo real. Este equilibrio entre una alta precisión en la detección, la exhaustividad y la robustez contra el sobreajuste convierten al modelo de 126 épocas en la solución más adecuada para las necesidades específicas de nuestro sistema de gestión de tráfico.

4.1.3. Contratación de hipótesis específica 3

- La implementación del modelo basado en Redes Neuronales Artificiales (RNA) permite desarrollar un algoritmo, que optimiza la duración de los ciclos en función de la densidad vehicular bajo condiciones variables de tráfico.

La implementación del modelo permitió desarrollar un algoritmo que optimiza dinámicamente la duración de los ciclos semafóricos según las condiciones de tráfico. El sistema captura grabaciones de 45 segundos durante la fase roja del semáforo principal (F. Vivanco), período ideal para el análisis ya que los vehículos están detenidos o en aproximación predecible. Durante los 45 segundos, realiza la detección, clasificación y conteo preciso de vehículos, analizando tanto los detenidos como aquellos en aproximación para calcular la densidad vehicular actual. A partir de este análisis, el algoritmo determina la duración óptima de las fases verde y ámbar para el semáforo 1 (F. Vivanco), así como los tiempos correspondientes para el semáforo perpendicular 2 (F. Vivanco y Jr. Sol), garantizando que todos los vehículos detectados puedan atravesar la intersección eficientemente mientras se minimizan los tiempos de espera.

Es importante destacar que la configuración del algoritmo para la optimización de los ciclos semafóricos se fundamenta en principios teóricos sólidamente validados y detallados en la sección 2.3.2.4. Se detalla a continuación el proceso, para la configuración del algoritmo que optimiza los ciclos semafóricos, según las condiciones variables de tráfico.

Diseño del algoritmo de optimización de ciclos semafóricos

1. Conteo vehicular

- El sistema detecta, clasifica y realiza un seguimiento de cada vehículo para evitar duplicados, cada vehículo detectado contribuye según su valor UCP.

```
Python

# Detección con YOLO
resultados = model.predict(frame, conf=conf_threshold, verbose=False)

# Procesar detecciones
detecciones_frame = []
for result in resultados:
    boxes = result.boxes
    for box in boxes:
        x1, y1, x2, y2 = map(int, box.xyxy[0])
        cls = int(box.cls[0])
        conf = float(box.conf[0])

        # Guardar para análisis
        detecciones_frame.append([x1, y1, x2, y2, cls, conf])

# Filtrado temporal para reducir falsos positivos
detecciones_filtradas = filtrar_detecciones_temporal(
    detecciones_frame,
    detecciones_historicas,
    frames_umbral=umbral_consistencia
)
```

Figura 145: Detecciones y filtrado temporal en el conteo vehicular
Fuente: Imagen propia

2. Contabilización de demanda total

- Suma ponderada según valores UCP específicos para cada clase del total de vehículos únicos detectados, se obtiene la “demanda total UCP”
- Densidad UCP = UCP Total / duración de observación, este valor representa la cantidad de vehículos equivalentes por unidad de tiempo.

```
Python 

# Cálculos finales
total_ucp = sum(ucp_total_por_clase.values())
total_vehiculos = len(vehiculos_unicos)
```

Figura 146: Contabilización de demanda total

Fuente: Imagen propia

3. Normalización a estándares de ingeniería

- Densidad UCP/km/h = Densidad UCP × 3600 / 1000 Conversión a unidades estándar para aplicación de criterios técnicos.
- Estos valores UCP reflejan el impacto relativo de cada tipo de vehículo en el flujo de tráfico .

```
Python 

# Convertir a densidad por kilómetro
densidad_ucp_km = densidad_ucp * 3600 / 1000 # UCP/km/h
```

Figura 147: Normalización a estándares de ingeniería

Fuente: Imagen propia

4. Determinación del grado de saturación:

- Grado de Saturación = Densidad UCP / Capacidad Ideal
- Se utiliza el valor de 1900 UCP/hora/carril como capacidad ideal se fundamenta en estudios de calibración de Federal Highway Administration (2006). Este valor representa condiciones geométricas ideales (carril de 3.6m, considerable pendiente, buen pavimento) y puede ajustarse según factores locales específicos. El Jirón Carlos F. Vivanco, presenta este tipo de condiciones geométricas, por lo que el valor de 1900 UCP/hora/carril se adecua específicamente.
- Se realizan ajustes para el grado de saturación, debido a que la relación entre demora y grado de saturación sigue una curva exponencial y no una relación lineal.

```
Python 

# Capacidad ideal estimada
capacidad_ideal_segundo = 1900 / 3600 # UCP/segundo/carril


# Grado de saturación
grado_saturacion = min(1.0, densidad_ucp / capacidad_ideal_segundo)
```

Figura 148: Determinación del grado de saturación

Fuente: Imagen propia

5. Determinación del tiempo verde base

- Las señales con ciclos cortos ayudan a que las calles urbanas funcionen como una red completa, reduciendo los tiempos de espera. Se requiere un tiempo mínimo de fase de 7 segundos, y los tiempos de cruce deben basarse en una velocidad mínima de cruce de 2,5-3,5 pies por segundo National Association of City Transportation Officials (2025). Esta consideración es especialmente importante para acomodar a personas mayores y niños que pueden necesitar más tiempo para cruzar.
- Estudios de psicología del conductor demostraron que tiempos verdes inferiores a 15 segundos generan frustración y aumentan violaciones semafóricas Brosseau et al. (2013).
- Se establece un tiempo en verde mínimo variable (15 a 18 segundos) el cual varía en función de la demanda UCP total.



```

Python

# Ajuste del tiempo verde base según UCP total
if ucp_total > 20:
    tiempo_verde_base = 18.0
elif ucp_total > 10:
    tiempo_verde_base = 16.0
else:
    tiempo_verde_base = 15.0
  
```

Figura 149: Determinación del tiempo verde base

Fuente: Imagen propia

6. Incremento proporcional basado en densidad

- La aplicación de incrementos escalonados según el grado de saturación se sustenta en los principios de compensación de Webster (2004) el cual demostró matemáticamente que intersecciones con accesos altamente saturados requieren asignaciones de tiempo proporcionalmente mayores.
- En la implementación del algoritmo, el incremento adicional en la duración de las fases semafóricas se calcula exclusivamente en función del grado de saturación, el cual se deriva directamente de la densidad (UCP). Esta lógica se adapta específicamente a las condiciones observadas en el Jirón Carlos F. Vivanco, donde la actividad de recogida de pasajeros genera patrones de tráfico particulares que justifican este ajuste adicional proporcional a la densidad vehicular.
- Se asuma una restricción de 60 segundos como tiempo verde máximo, debido a investigaciones realizadas por Akcelik el cual demuestra que tiempos verdes superiores a 60 segundos generan demoras excesivas en los accesos secundarios.

Python



```
# Incremento adicional con escala progresiva
if grado_saturacion > 0.8:
    incremento_adicional = 1.0 + (0.25 * grado_saturacion) # Hasta 25% extra
elif grado_saturacion > 0.5:
    incremento_adicional = 1.0 + (0.20 * grado_saturacion) # Hasta 20% extra
else:
    incremento_adicional = 1.0 + (0.18 * grado_saturacion) # Hasta 18% extra
```

Figura 150: Incremento proporcional basado en la densidad

Fuente: Imagen propia

7. Factor de escala por demanda total

- Se aplica un factor multiplicador basado directamente en la demanda UCP total: $\text{Factor} = \min(1.20, \max(1.0, \text{UCP Total}/25))$. Este factor reconoce explícitamente que intersecciones con mayor demanda requieren ciclos proporcionalmente más largos.
- Estudios de microsimulación realizados con TRANSYT han confirmado que factores de escala adicionales, más allá del grado de saturación, son necesarios para optimizar la operación de intersecciones con alto volumen total de tráfico.

Python



```
# Factor de escalamiento directo basado en UCP total
factor_escal_ucp = min(1.20, max(1.0, ucp_total / 25)) # Suavizado a 1.0-1.20x
```

Figura 151: Factor de escala por demanda total

Fuente: Imagen propia

8. Cálculo del tiempo verde final

- El tiempo verde se limita entre el tiempo verde base y un máximo de 60 segundos. Para el semáforo 1 se calcula combinando todos estos factores:

Python



```
tiempo_verde_sem1 = tiempo_verde_base + (factor_webster * factor_ajuste * factor_e:
tiempo_verde_sem1 = tiempo_verde_sem1 * incremento_adicional
```

Figura 152: Cálculo del tiempo verde final

Fuente: Imagen propia

9. Cálculo del tiempo ámbar

- El concepto de zona de dilema asociada a la luz en ambar es ampliamente reconocido como un área en la aproximación a una intersección de alta velocidad, donde los vehículos no pueden ni detenerse con seguridad antes de la línea de parada ni atravesar la intersección durante el intervalo ámbar

aumenta en condiciones de alta densidad debido al efecto de seguimiento vehicular. Zhang et al. (2014).

- Los ciclos semafóricos en ámbar varían típicamente entre 3 y 5 segundos. Esta duración ha sido determinada considerando factores críticos como el tiempo de percepción-reacción del conductor (aproximadamente 1-1.5 segundos), la velocidad promedio de aproximación a la intersección, y la distancia de frenado seguro. Investigaciones en seguridad vial demuestran que un intervalo inferior a 3 segundos resulta insuficiente para una reacción adecuada, mientras que períodos superiores a 5 segundos pueden provocar impaciencia, incrementando la probabilidad de que los conductores ignoren la señalización e ingresen a la intersección durante esta fase. El tiempo ámbar en nuestro algoritmo se ajusta según la densidad del tráfico.

```
Python 
```

```
tiempo_ambar_base = 3.0
ajuste_densidad = np.sqrt(grado_saturacion) * 1.2
tiempo_ambar_sem1 = tiempo_ambar_base + min(2.0, ajuste_densidad)
tiempo_ambar_sem1 = max(3.0, min(5.0, tiempo_ambar_sem1))
```

Figura 153: Cálculo del tiempo ámbar
Fuente: Imagen propia

10. Cálculo de los ciclos-semáforo 2

- El cálculo para el tiempo en rojo y ámbar para el semáforo 2:


```
Python 
```

```
tiempo_despeje = 1.0 # Tiempo de seguridad entre cambios
tiempo_rojo_sem2 = tiempo_verde_sem1 + tiempo_ambar_sem1 + tiempo_despeje
tiempo_ambar_sem2 = tiempo_ambar_sem1
```

Figura 154: Cálculo de los ciclos-semáforo 2
Fuente: Imagen propia

11. Determinación del ciclo total

- El ciclo semafórico completo se calcula como la suma del ciclo en verde y ambar optimizado, adicionando un segundo adicional el cual corresponde al tiempo de despeje (también conocido como all-red time). Este breve período es una medida de seguridad implementada en los sistemas semafóricos debido a que, permite que los vehículos que ya han ingresado a la intersección durante el ámbar terminen de cruzarla completamente antes de que el tráfico perpendicular comience a moverse, también, reduce el riesgo de accidentes laterales (conocidos como colisiones "T-bone") y protege a los conductores que cruzan en rojo justo al cambiar la luz.



```
Python
ciclo_total = tiempo_verde_seml + tiempo_ambar_seml + tiempo_despeje
```

Figura 155: Determinación del ciclo total

Fuente: Imagen propia

12. Evaluación del nivel de servicio

- La evaluación del nivel de servicio se llevará a cabo mediante una adaptación del manual HCM, ajustada a las particularidades de nuestro contexto. Este método modificado clasifica la calidad del flujo vehicular en seis niveles (A a F) basándose en la densidad (UCP), con los siguientes umbrales: nivel A (<9 UCP - flujo libre), nivel B (9-14 UCP - flujo estable razonable), nivel C (14-19 UCP - flujo estable), nivel D (19-24 UCP - flujo próximo a inestable), nivel E (24-29 UCP - flujo inestable) y nivel F (>29 UCP - flujo forzado o congestionado).



```
Python
if ucp_total < 9:
    return "A", "Flujo libre", "green"
elif ucp_total < 14:
    return "B", "Flujo estable razonable", "lightgreen"
# etc.
```

Figura 156: Evaluación del nivel de servicio

Fuente: Imagen propia

13. Integración del algoritmo

enfoque integrador, construido sobre una base firme de principios de ingeniería de tránsito, teoría de colas, dinámica de fluidos vehiculares y estudios empíricos internacionales, garantiza la robustez, adaptabilidad y eficacia operativa de nuestro sistema de predicción semafórica. El algoritmo desarrollado representa un avance significativo en la optimización semafórica, fusionando la solidez de la ingeniería de tránsito clásica con enfoques innovadores. Su capacidad para responder con precisión a las variaciones en la demanda y la composición vehicular, junto con su fiabilidad operacional y beneficios comprobados, aseguran una mejora sustancial en la movilidad urbana, la reducción de impactos ambientales y la optimización de la infraestructura vial existente.

Optimización de ciclos semafóricos mediante Google Colab

1. Acceso a recursos de alto rendimiento.

- Google Colab proporciona acceso gratuito a GPUs, lo que aceleró significativamente el procesamiento de video y la detección de vehículos mediante el modelo YOLO entrenado, tareas que resultaban extremadamente lentas en un entorno local con recursos limitados.



Figura 157: Uso del GPU-T4

Fuente: Imagen propia

2. Procesamiento en la nube y bibliotecas:

- Todo el procesamiento intensivo, desde la detección de objetos hasta los cálculos de UCP y la generación de visualizaciones, se ejecuta en servidores de Google, eliminando la carga del hardware local.




Figura 158: Montaje del google drive.

Fuente: Imagen propia

- Colab ya incluye muchas de las bibliotecas necesarias (OpenCV, NumPy, Matplotlib), simplificando la configuración del entorno de desarrollo, otras pueden ser instaladas fácilmente (ultralytics).




Figura 159: Instalación de ultralytics

Fuente: Imagen propia

3. Persistencia y accesibilidad de datos:

- La integración con Google Drive facilitó el almacenamiento y acceso tanto a los videos de entrada como a los resultados generados, permitiendo retomar el análisis en diferentes sesiones.




Figura 160: Almacenamiento de vídeos en el Google Drive
Fuente: Imagen propia

4. Interfaz de Colab realizando el procesamiento:

- Interfaz de Google Colab en el procesamiento para la grabación 01.




Figura 161: Inicio del procesamiento-grabación 01
Fuente: Imagen propia




Figura 162: Ejecución final del procesamiento- 01
Fuente: Imagen propia

```

Entrenamiento cámara 01.ipynb
Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda

Comandos + Código + Texto

Tiempo verde base: 15.00 segundos

Generando visualizaciones actualizadas con el algoritmo integrado...
Gráfico guardado: /content/drive/MyDrive/yolo_dataset/comprobacion/graficos/semaforos_prediccion.png
Gráfico guardado: /content/drive/MyDrive/yolo_dataset/comprobacion/graficos/distribucion_ucp.png
Inicio: Usando un fondo en blanco para el mapa de calor (frame Final no disponible)
Mapa de calor generado con éxito: /content/drive/MyDrive/yolo_dataset/comprobacion/graficos/mapa_calor.png
Gráfico guardado: /content/drive/MyDrive/yolo_dataset/comprobacion/graficos/analisis_graficos.png
Gráfico guardado: /content/drive/MyDrive/yolo_dataset/comprobacion/graficos/comparativa_eficiencia.png

===== Verificación de gráficos generados =====
[✓] Analisis completo: Generado correctamente (/content/drive/MyDrive/yolo_dataset/comprobacion/graficos/analisis_graficos.png)
[✓] Semaforos: Generado correctamente (/content/drive/MyDrive/yolo_dataset/comprobacion/graficos/semaforos_prediccion.png)
[✓] Distribución UCP: Generado correctamente (/content/drive/MyDrive/yolo_dataset/comprobacion/graficos/distribucion_ucp.png)
[✓] Mapa de calor: Generado correctamente (/content/drive/MyDrive/yolo_dataset/comprobacion/graficos/mapa_calor.png)
[✓] Comparativa de eficiencia: Generado correctamente (/content/drive/MyDrive/yolo_dataset/comprobacion/graficos/comparativa_eficiencia.png)

Total: 5/5 gráficos generados correctamente

[✓] Visualizaciones actualizadas generadas en la carpeta:
/content/drive/MyDrive/yolo_dataset/comprobacion/graficos/

===== Analisis completo finalizado con algoritmo integrado =====
Filtrado temporal: 2 de 3 frames para validar detecciones
Factor de escala UCP: 1.00x
Tiempo verde base variable: 15.00s
Incremento aplicado: 11.27%
Tiempo verde calculado para Semaforo 1: 26.38 segundos
Tiempo semar calculado para Semaforo 1: 3.30 segundos
Tiempo rojo calculado para Semaforo 2: 31.28 segundos
Tiempo semar calculado para Semaforo 2: 3.30 segundos
Ciclo semaforico completo: 31.28 segundos

El sistema ahora cuenta con un algoritmo integrado que combina:
- Tiempo base variable según el volumen de tráfico
- Factor de escala según UCP total
- Incremento proporcional al grado de saturación
- Filtrado temporal para eliminar falsos positivos
Esto proporciona tiempos semaforicos más equilibrados y adaptados a las condiciones reales de tráfico.
(Figure size 1400x800 with 0 Axes)
(Figure size 1200x800 with 0 Axes)

```

Figura 163: Ejecución final del procesamiento- 02

Fuente: Imagen propia

5. Exportación de vídeo procesado

- Una de las funcionalidades más valiosas del modelo es la generación de un video de salida que muestra en tiempo real:
- La detección y clasificación de cada vehículo con bounding boxes de colores específicos según la clase, etiquetas detalladas con ID único, tipo de vehículo, valor UCP y nivel de confianza.
- Trayectorias de movimiento de cada vehículo visualizadas mediante líneas, contadores en tiempo real del número de vehículos por clase y totales, finalmente indicadores de filtrado temporal que muestran la reducción de falsos positivos.




Figura 164: Vídegrabación 01 exportada

Fuente: Imagen propia

6. Exportación de datos estructurados:

- El modelo guarda automáticamente, archivos CSV con conteos detallados por clase de vehículo y valores UCP.
- El modelo guarda resultados completos de la optimización semafórica, incluyendo todos los parámetros calculados, métricas de rendimiento como tiempos de procesamiento y FPS.

	A	B	C	D	E
1	clase	nombre	conteo	ucp_unitario	ucp_total
2		0 A	7	1	7
3		1 MB	1	2.5	2.5
4		2 M	1	0.33	0.33
5		5 PU	2	1.25	2.5
6		6 MT	1	0.75	0.75
7	TOTAL		12		13.08

Figura 165: Análisis resultado-detección y conteo en formato.CSV
Fuente: Imagen propia

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
1	entb_veh1	entbr_veh1	rip_veh2	entbr_veh2	visu_veh	derivado_veh	derivado_veh_2h	prof_veh	factor_ajuste	incremento_ajuste	factor_veh_veh_1	tempo_veh_veh_1	tempo_veh_veh_2	derivado_veh_2h_2h	derivado_veh_2h_2h
2	26.3834335	3.90962269	31.28394802	3.90962269	31.28394802	0.2972727273	1.070191818	0.58253585	1.02803805	1.12860718	1	16	16	Flujo estable razonable (23)	Flujo estable razonable (23)

Figura 166: Análisis resultado-optimización de los ciclos semaforicos en formato.CSV
Fuente: Imagen propia

7. Generación del gráfico análisis completo de tráfico:

- El modelo genera una visualización integral de análisis de tráfico que combina múltiples perspectivas analíticas en un único panel informativo.
- Fusiona datos cuantitativos de distribución vehicular mediante un gráfico circular codificado por colores que identifica la proporción exacta de cada tipo de vehículo según su valor UCP.
- Genera un análisis comparativo de los ciclos semaforicos optimizados (versus estándar del semáforo de tiempo fijo de 50 segundos, con el optimizado).
- Sintetiza, el proceso de predicción de los ciclos semaforicos, el nivel de servicio de la intersección, y finalmente un conjunto exhaustivo de métricas técnicas precisas (incluyendo densidad UCP, grado de saturación y factores de ajuste) que fundamentan las decisiones algorítmicas tomadas.




Figura 167: Gráfico análisis completo de tráfico-grabación 01
Fuente: Imagen propia

8. Generación de gráfico de ciclos semafóricos optimizados

- El modelo genera el gráfico ciclo semafórico optimizado, que representa una visualización técnica mediante barras horizontales apiladas que muestra la sincronización precisa entre los dos semáforos pertenecientes al Jiron Carlos F. Vivanco.
- El Semáforo 1 exhibe una fase verde optimizada y ambar (reducida respecto al estándar de 50 segundos).
- El Semáforo 2 muestra su correspondiente fase roja (exactamente la suma del verde y ámbar del Semáforo 1 adicionando un segundo adicional que es el tiempo de despegue) seguida por la misma duración de fase ámbar.
- El panel inferior contextualiza estos valores indicando un nivel de servicio, la densidad UCP, el grado de saturación, detalla las optimizaciones técnicas aplicadas por el algoritmo, incluyendo el filtrado temporal para eliminar falsos positivos y el incremento variable de acuerdo la densidad, comunicando eficientemente cómo el sistema ha adaptado los tiempos semafóricos a las condiciones reales de tráfico detectadas.




Figura 168: Gráfico ciclos semafóricos optimizados-grabación 01

Fuente: Imagen propia

9. Generación del gráfico comparativo de eficiencia sistema estándar vs. integrado(optimizado)

- El modelo genera un gráfico comparativo de eficiencia del sistema estándar vs integrado (optimizado).
- Los valores porcentuales mostrados en el gráfico reflejan una relación directamente proporcional con el tiempo de espera.
- Las reducciones en consumo de combustible y emisiones de CO2 son calculadas con base en la reducción del tiempo de espera, ya que un menor tiempo de detención de los vehículos implica proporcionalmente menor consumo de combustible y menos emisiones.
- Los valores resultantes son relativos porque toman como punto de referencia (100 %) el cual representa el tiempo del semáforo fijo estándar,

partiendo de ese punto se obtienen las mejoras porcentuales que ofrece el semáforo optimizado, estableciendo así una correlación directa entre la optimización del tiempo y las mejoras en eficiencia de combustible y emisiones de CO₂.




Figura 169: Vídeo exportado 01

Fuente: Imagen propia

10. Almacenamiento eficiente en la nube:

- Todos los resultados generados (videos, visualizaciones y datos) se exportan automáticamente al Google Drive vinculado, lo que permite: Acceso inmediato a los resultados desde cualquier dispositivo, compartir fácilmente los hallazgos con colaboradores, conservar un registro histórico de los análisis realizados.




Figura 170: Visualización del vídeo procesado

Fuente: Vídeo procesado

Se evaluó el modelo utilizando 32 videograbaciones que representan una variedad de escenarios de tráfico, con el objetivo de establecer los ciclos semafóricos optimizados en función de la demanda vehicular mediante Google Colab.

Resultados análisis completo de tráfico, con algoritmo integrado y filtrado temporal




Figura 171: Análisis completo de tráfico-grab 01
Fuente: Imagen propia




Figura 172: Análisis completo de tráfico-grab 02
Fuente: Imagen propia




Figura 173: Análisis completo de tráfico-grab 03
Fuente: Imagen propia




Figura 174: Análisis completo de tráfico-grab 04
 Fuente: Imagen propia




Figura 175: Análisis completo de tráfico-grab 05
 Fuente: Imagen propia




Figura 176: Análisis completo de tráfico-grab 06
 Fuente: Imagen propia




Figura 177: Análisis completo de tráfico-grab 07
 Fuente: Imagen propia




Figura 178: Análisis completo de tráfico-grab 08
 Fuente: Imagen propia




Figura 179: Análisis completo de tráfico-grab 09
 Fuente: Imagen propia




Figura 180: Análisis completo de tráfico-grab 10
 Fuente: Imagen propia




Figura 181: Análisis completo de tráfico-grab 11
 Fuente: Imagen propia




Figura 182: Análisis completo de tráfico-grab 12
 Fuente: Imagen propia




Figura 183: Análisis completo de tráfico-grab 13
 Fuente: Imagen propia




Figura 184: Análisis completo de tráfico-grab 14
 Fuente: Imagen propia




Figura 185: Análisis completo de tráfico-grab 15
 Fuente: Imagen propia




Figura 186: Análisis completo de tráfico-grab 16
Fuente: Imagen propia




Figura 187: Análisis completo de tráfico-grab 17
Fuente: Imagen propia




Figura 188: Análisis completo de tráfico-grab 18
Fuente: Imagen propia




Figura 189: Análisis completo de tráfico-grab 19
Fuente: Imagen propia




Figura 190: Análisis completo de tráfico-grab 20
Fuente: Imagen propia




Figura 191: Análisis completo de tráfico-grab 21
Fuente: Imagen propia




Figura 192: Análisis completo de tráfico-grab 22
Fuente: Imagen propia




Figura 193: Análisis completo de tráfico-grab 23
Fuente: Imagen propia




Figura 194: Análisis completo de tráfico-grab 24
Fuente: Imagen propia




Figura 195: Análisis completo de tráfico-grab 25
Fuente: Imagen propia




Figura 196: Análisis completo de tráfico-grab 26
Fuente: Imagen propia




Figura 197: Análisis completo de tráfico-grab 27
Fuente: Imagen propia




Figura 198: Análisis completo de tráfico-grab 28
Fuente: Imagen propia




Figura 199: Análisis completo de tráfico-grab 29
Fuente: Imagen propia




Figura 200: Análisis completo de tráfico-grab 30
Fuente: Imagen propia




Figura 201: Análisis completo de tráfico-grab 31
 Fuente: Imagen propia




Figura 202: Análisis completo de tráfico-grab 32
 Fuente: Imagen propia

Cuadro 18: Análisis completo de tráfico vehicular

Grab.	Total veh.	Valor UCP acum.	Dens. UCP	Grado sat.	Incram. apl.	Factor UCP
1	12	13.08	1.07	0.56	11.3 %	1.00 %
2	11	13.91	1.09	0.58	11.5 %	1.00 %
3	9	8.49	0.67	0.35	6.4 %	1.00 %
4	18	23.07	1.83	0.96	24.1 %	1.00 %
5	9	8.74	0.69	0.36	6.5 %	1.00 %
6	16	23.66	1.86	0.98	24.5 %	1.00 %
7	21	27.48	2.17	1.00	25.0 %	1.10 %
8	19	23.73	1.82	0.96	23.9 %	1.00 %
9	18	26.57	2.12	1.00	25.0 %	1.06 %
10	21	25.40	2.02	1.00	25.0 %	1.02 %
11	19	15.30	1.21	0.64	12.8 %	1.00 %
12	18	27.41	2.17	1.00	25.0 %	1.10 %
13	17	26.25	2.07	1.00	25.0 %	1.05 %
14	16	19.14	1.51	0.80	15.9 %	1.00 %
15	23	29.06	2.31	1.00	25.0 %	1.16 %
16	13	10.06	0.82	0.43	7.7 %	1.00 %
17	20	24.73	1.94	1.00	25.0 %	1.00 %
18	12	8.14	0.64	0.34	6.1 %	1.00 %
19	18	20.49	1.62	0.85	21.3 %	1.00 %
20	24	18.12	1.45	0.76	15.2 %	1.00 %
21	23	30.22	2.39	1.00	25.0 %	1.20 %
22	19	20.23	1.88	0.99	24.7 %	1.00 %
23	23	19.97	1.58	0.83	20.8 %	1.00 %
24	18	13.47	1.13	0.59	11.8 %	1.00 %
25	12	14.33	1.12	0.59	11.8 %	1.00 %
26	13	9.23	0.77	0.41	7.3 %	1.00 %
27	7	5.82	0.46	0.24	4.3 %	1.00 %
28	15	10.98	0.89	0.47	8.5 %	1.00 %
29	20	18.39	1.46	0.77	15.4 %	1.00 %
30	16	11.22	0.90	0.47	8.5 %	1.00 %
31	14	8.64	0.69	0.36	6.5 %	1.00 %
32	12	10.66	0.87	0.46	8.3 %	1.00 %

Resultados de los ciclos semafóricos optimizados en función de la densidad (UCP)




Figura 203: Ciclos semafóricos-grab 01-Densidad UCP: 1.07 UCP/km/h
 Fuente: Imagen propia




Figura 204: Ciclos semafóricos-grab 02-Densidad UCP: 1.09 UCP/km/h
 Fuente: Imagen propia




Figura 205: Ciclos semafóricos-grab 03-Densidad UCP: 0.67 UCP/km/h
 Fuente: Imagen propia




Figura 206: Ciclos semafóricos-grab 04-Densidad UCP: 1.83 UCP/km/h
 Fuente: Imagen propia.




Figura 207: Ciclos semafóricos-grab 05-Densidad UCP: 0.69 UCP/km/h
 Fuente: Imagen propia




Figura 208: Ciclos semafóricos-grab 06-Densidad UCP: 1.86 UCP/km/h
 Fuente: Imagen propia




Figura 209: Ciclos semafóricos-grab 07-Densidad UCP: 2.17 UCP/km/h
Fuente: Imagen propia




Figura 210: Ciclos semafóricos-grab 08-Densidad UCP: 1.82 UCP/km/h
Fuente: Imagen propia




Figura 211: Ciclos semafóricos-grab 09-Densidad UCP: 2.12 UCP/km/h
Fuente: Imagen propia




Figura 212: Ciclos semafóricos-grab 10-Densidad UCP: 2.02 UCP/km/h
 Fuente: Imagen propia




Figura 213: Ciclos semafóricos-grab 11-Densidad UCP: 1.21 UCP/km/h
 Fuente: Imagen propia




Figura 214: Ciclos semafóricos-grab 12-Densidad UCP: 2.17 UCP/km/h
 Fuente: Imagen propia




Figura 215: Ciclos semafóricos-grab 13-Densidad UCP: 2.07 UCP/km/h
Fuente: Imagen propia




Figura 216: Ciclos semafóricos-grab 14-Densidad UCP: 1.51 UCP/km/h
Fuente: Imagen propia




Figura 217: Ciclos semafóricos-grab 15-Densidad UCP: 2.31 UCP/km/h
Fuente: Imagen propia




Figura 218: Ciclos semafóricos-grab 16-Densidad UCP: 0.82 UCP/km/h
 Fuente: Imagen propia




Figura 219: Ciclos semafóricos-grab 17-Densidad UCP: 1.94 UCP/km/h
 Fuente: Imagen propia




Figura 220: Ciclos semafóricos-grab 18-Densidad UCP: 0.64 UCP/km/h
 Fuente: Imagen propia




Figura 221: Ciclos semafóricos-grab 19-Densidad UCP: 1.62 UCP/km/h
 Fuente: Imagen propia




Figura 222: Ciclos semafóricos-grab 20-Densidad UCP: 1.45 UCP/km/h
 Fuente: Imagen propia




Figura 223: Ciclos semafóricos-grab 21-Densidad UCP: 2.39 UCP/km/h
 Fuente: Imagen propia




Figura 224: Ciclos semafóricos-grab 22-Densidad UCP: 1.88 UCP/km/h
 Fuente: Imagen propia




Figura 225: Ciclos semafóricos-grab 23-Densidad UCP: 1.58 UCP/km/h
 Fuente: Imagen propia




Figura 226: Ciclos semafóricos-grab 24-Densidad UCP: 1.13 UCP/km/h
 Fuente: Imagen propia




Figura 227: Ciclos semafóricos-grab 25-Densidad UCP: 1.12 UCP/km/h
 Fuente: Imagen propia




Figura 228: Ciclos semafóricos-grab 26-Densidad UCP: 0.77 UCP/km/h
 Fuente: Imagen propia




Figura 229: Ciclos semafóricos-grab 27-Densidad UCP: 0.46 UCP/km/h
 Fuente: Imagen propia




Figura 230: Ciclos semafóricos-grab 28-Densidad UCP: 0.89 UCP/km/h
 Fuente: Imagen propia




Figura 231: Ciclos semafóricos-grab 29-Densidad UCP: 1.46 UCP/km/h
 Fuente: Imagen propia




Figura 232: Ciclos semafóricos-grab 30-Densidad UCP: 0.90 UCP/km/h
 Fuente: Imagen propia




Figura 233: Ciclos semafóricos-grab 31-Densidad UCP: 0.69 UCP/km/h
 Fuente: Imagen propia




Figura 234: Ciclos semafóricos-grab 32-Densidad UCP: 0.87 UCP/km/h
 Fuente: Imagen propia

Cuadro 19: Resultados de los ciclos semafóricos optimizados en función de la densidad (UCP)

Grab.	Nivel de servicio	Dens.UCP	T.verde-Sem 01	T.ambar-Sem 01	T.rojo-Sem 02
1	B-Flujo estable razonable	1.07	26.4	3.9	31.3
2	B-Flujo estable razonable	1.09	26.6	3.9	31.5
3	A-Flujo libre	0.67	22.0	3.7	26.7
4	D-Flujo próximo a inestable	1.83	36.8	4.2	42
5	A-Flujo libre	0.69	22.2	3.7	26.9
6	D-Flujo próximo a inestable	1.86	37.1	4.2	42.3
7	E-Flujo inestable	2.17	39.0	4.2	44.2
8	D-Flujo próximo a inestable	1.82	36.7	4.2	41.8
9	E-Flujo inestable	2.12	38.4	4.2	43.6
10	E-Flujo inestable	2.02	37.7	4.2	42.9
11	C-Flujo estable	1.21	27.5	4.0	32.4
12	E-Flujo inestable	2.17	38.9	4.2	44.1
13	E-Flujo inestable	2.07	38.2	4.2	43.5
14	C-Flujo estable	1.51	30.3	4.1	35.4
15	E-Flujo inestable	2.31	39.9	4.2	45.1
16	B-Flujo estable razonable	0.82	24.2	3.8	29.0
17	E-Flujo inestable	1.94	37.5	4.2	42.7
18	A-Flujo libre	0.64	21.8	3.7	26.5
19	D-Flujo próximo a inestable	1.62	34.8	4.1	39.9
20	C-Flujo estable	1.45	29.7	4.0	34.8
21	F-Flujo forzado o congestionado	2.39	40.5	4.2	45.7
22	D-Flujo próximo a inestable	1.88	37.3	4.2	42.5
23	D-Flujo próximo a inestable	1.58	32.0	4.1	37.1
24	C-Flujo estable	1.13	26.8	3.9	31.7
25	C-Flujo estable	1.12	26.8	3.9	31.7
26	B-Flujo estable razonable	0.77	22.8	3.8	27.5
27	A-Flujo libre	0.46	20.3	3.6	24.9
28	B-Flujo estable razonable	0.89	24.8	3.8	29.6
29	C-Flujo estable	1.46	29.8	4.1	34.9
30	B-Flujo estable razonable	0.90	24.8	3.8	29.6
31	A-Flujo libre	0.69	22.1	3.7	26.8
32	B-Flujo estable razonable	0.87	24.6	3.8	29.5

Fuente: Elaboración propia.

Resultados comparativa del sistema estandar vs integrado (optimizado)




Figura 235: Comparativa sistema estandar vs optimizado-grab 01
Fuente: Imagen propia




Figura 236: Comparativa sistema estandar vs optimizado-grab 02
Fuente: Imagen propia




Figura 237: Comparativa sistema estandar vs optimizado-grab 03
Fuente: Imagen propia




Figura 238: Comparativa sistema estandar vs optimizado-grab 04
Fuente: Imagen propia




Figura 239: Comparativa sistema estandar vs optimizado-grab 05
Fuente: Imagen propia




Figura 240: Comparativa sistema estandar vs optimizado-grab 06
Fuente: Imagen propia




Figura 241: Comparativa sistema estandar vs optimizado-grab 07
Fuente: Imagen propia




Figura 242: Comparativa sistema estandar vs optimizado-grab 08
Fuente: Imagen propia




Figura 243: Comparativa sistema estandar vs optimizado-grab 09
Fuente: Imagen propia




Figura 244: Comparativa sistema estandar vs optimizado-grab 10
Fuente: Imagen propia




Figura 245: Comparativa sistema estandar vs optimizado-grab 11
Fuente: Imagen propia




Figura 246: Comparativa sistema estandar vs optimizado-grab 12
Fuente: Imagen propia




Figura 247: Comparativa sistema estandar vs optimizado-grab 13
Fuente: Imagen propia




Figura 248: Comparativa sistema estandar vs optimizado-grab 14
Fuente: Imagen propia




Figura 249: Comparativa sistema estandar vs optimizado-grab 15
Fuente: Imagen propia




Figura 250: Comparativa sistema estandar vs optimizado-grab 16
Fuente: Imagen propia




Figura 251: Comparativa sistema estandar vs optimizado-grab 17
Fuente: Imagen propia




Figura 252: Comparativa sistema estandar vs optimizado-grab 18
Fuente: Imagen propia




Figura 253: Comparativa sistema estandar vs optimizado-grab 19
Fuente: Imagen propia




Figura 254: Comparativa sistema estandar vs optimizado-grab 20
Fuente: Imagen propia




Figura 255: Comparativa sistema estandar vs optimizado-grab 21
Fuente: Imagen propia




Figura 256: Comparativa sistema estandar vs optimizado-grab 22
Fuente: Imagen propia




Figura 257: Comparativa sistema estandar vs optimizado-grab 23
Fuente: Imagen propia




Figura 258: Comparativa sistema estandar vs optimizado-grab 24
Fuente: Imagen propia




Figura 259: Comparativa sistema estandar vs optimizado-grab 25
Fuente: Imagen propia




Figura 260: Comparativa sistema estandar vs optimizado-grab 26
Fuente: Imagen propia




Figura 261: Comparativa sistema estandar vs optimizado-grab 27
Fuente: Imagen propia




Figura 262: Comparativa sistema estandar vs optimizado-grab 28
Fuente: Imagen propia




Figura 263: Comparativa sistema estandar vs optimizado-grab 29
Fuente: Imagen propia




Figura 264: Comparativa sistema estandar vs optimizado-grab 30
Fuente: Imagen propia




Figura 265: Comparativa sistema estandar vs optimizado-grab 31
Fuente: Imagen propia




Figura 266: Comparativa sistema estandar vs optimizado-grab 32
Fuente: Imagen propia

5. CONCLUSIONES

5.1. Conclusiones

El presente trabajo investigativo ha logrado alcanzar satisfactoriamente todos los objetivos específicos propuestos inicialmente, lo que consecuentemente ha permitido cumplir con el objetivo general establecido. La investigación ha generado descubrimientos relevantes que sustentan firmemente las hipótesis formuladas al inicio del estudio.

- **01:** Desarrollar el diseño del modelo basado en Redes Neuronales Artificiales (RNA), que permita ajustar una arquitectura para la detección, clasificación y conteo eficiente de vehículos en condiciones heterogéneas, que incluyen tráfico variable, diversas condiciones ambientales (precipitaciones, iluminación solar variable, sombras proyectadas) y entornos nocturnos con visibilidad limitada.

El modelo de detección vehicular basado en la arquitectura YOLO (You Only Look Once) ha demostrado una notable capacidad para cumplir con el objetivo planteado de detección, clasificación y conteo eficiente de vehículos bajo condiciones heterogéneas cumpliendo satisfactoriamente con la hipótesis específica planteada. Los resultados obtenidos evidencian la robustez del modelo para operar en escenarios de alta complejidad, manteniendo niveles consistentes de rendimiento bajo diversas condiciones. El modelo personalizado con pesos específicamente entrenados (bestfinal.pt) ha logrado reconocer efectivamente 8 categorías de vehículos bajo condiciones heterogéneas, la implementación del sistema de filtrado temporal avanzado ha sido crucial para discriminar entre objetos reales y artefactos ambientales, manteniendo la integridad del seguimiento vehicular mediante la asignación de identificadores únicos con persistencia entre frames. El modelo demuestra una notable adaptabilidad a variables críticas como diferentes densidades de tráfico (desde 7 hasta 24 vehículos), ciclos completos de iluminación (madrugada, mañana, tarde y noche), condiciones climáticas adversas (lluvia intensa, tenue y deslumbramiento), oclusiones parciales o totales de vehículos. La capacidad de visualización de trayectorias mediante un sistema de colores diferenciado por tipo de vehículo facilita la validación visual y el seguimiento intuitivo del flujo vehicular. Esta arquitectura representa un avance significativo para aplicaciones de monitoreo de tráfico en entornos urbanos, donde las condiciones heterogéneas son la norma más que la excepción, contribuyendo así a sistemas de transporte inteligente más eficientes y seguros.

- **02:** Simular el entrenamiento del modelo basado en Redes Neuronales Artificiales (RNA), para lograr un equilibrio óptimo entre la precisión en la detección, la exhaustividad en el reconocimiento de vehículos y la robustez contra el sobreajuste.

El proceso de entrenamiento del modelo ha permitido alcanzar un equilibrio óptimo entre la precisión en la detección, la exhaustividad en el reconocimiento de vehículos y la robustez contra el sobreajuste, cumpliendo satisfactoriamente con la hipótesis específica planteada. Los resultados obtenidos tras un riguroso análisis de diversas configuraciones de épocas (1, 20, 50, 100, 126 y 150) demuestran que el modelo entrenado con 126 épocas representa el punto de equilibrio óptimo gracias a la implementación del mecanismo de Early Stopping, que identificó con precisión el momento ideal para detener el aprendizaje, evitando así el fenómeno de sobreajuste. Este modelo exhibe un comportamiento refinado y preciso con métricas de rendimiento sobresalientes: un mAP50 de 0.892 y mAP50-95 de 0.792, indicando una efectividad excepcional tanto en la identificación correcta de objetos como en la detección de la mayoría de los vehículos presentes. El modelo entrenado con 126 épocas logra una precisión del 88.7%, confirmando que cuando el modelo detecta un objeto, es correcto en casi 9 de cada 10 casos. Simultáneamente, mantiene valores de recall de 0.832 (validación) y 0.834 (evaluación), demostrando su capacidad para identificar una proporción significativa de los vehículos realmente presentes en las escenas. La eficiencia del modelo es excepcional, con tiempos de procesamiento ultrarrápidos: 0.3ms para preprocesamiento, 5.5ms para inferencia (reducido a 2.6ms en validación) y 0.7ms para postprocesamiento por imagen. Estos valores son críticos para implementaciones en tiempo real, facilitando el análisis instantáneo de flujos de tráfico. La consistencia entre los tiempos de validación y evaluación (2.6ms/4.7ms para inferencia) confirma la estabilidad del modelo en diferentes contextos operativos. Estos indicadores reflejan un equilibrio crítico entre detección correcta y exhaustividad, fundamental para aplicaciones de conteo vehicular y gestión de tráfico urbano.

- **O3:** Determinar como la implementación del modelo basado en Redes Neuronales Artificiales (RNA) permite desarrollar un algoritmo, que optimice la duración de los ciclos en función de la densidad vehicular bajo condiciones variables de tráfico.

La implementación del modelo ha permitido desarrollar un algoritmo que optimiza eficazmente la duración de los ciclos semafóricos en función directa de la densidad vehicular bajo condiciones variables de tráfico, cumpliendo satisfactoriamente con la hipótesis específica planteada. El modelo desarrollado demuestra una notable capacidad para adaptar dinámicamente los tiempos semafóricos a las condiciones reales mediante un proceso estructurado y fundamentado en principios de ingeniería de tránsito. Esta correlación directa entre densidad vehicular y tiempos semafóricos queda evidenciada en el Cuadro 18 resultados de optimización de ciclos semafóricos basados en la densidad vehicular, donde las grabaciones con densidades UCP bajas (0.46-0.69)

generaron tiempos verde entre 20.3-22.2 segundos, las densidades medias (1.07-1.58) produjeron ciclos entre 26.4-32.0 segundos, y las densidades altas (1.82-2.39) resultaron en tiempos óptimos entre 36.7-40.5 segundos, demostrando la precisión del sistema para ajustarse proporcionalmente a diferentes niveles de congestión. De manera adicional el modelo determina el nivel de servicio de la intersección (de A a F) el cual se fundamenta en una adaptación específica del Manual HCM ajustada a las particularidades del Jirón Carlos F. Vivanco, el modelo genera también gráficos comparativos de eficiencia los cuales presentan valores relativos que, aunque expresados en porcentajes, obedecen estrictamente al tiempo de espera como variable fundamental, tomando como referencia base (100 %) el tiempo del semáforo fijo estándar, calculando las mejoras proporcionales en eficiencia de combustible y emisiones de CO₂ como consecuencia directa de la reducción en el tiempo de detención vehicular. El enfoque integrador del algoritmo, construido sobre principios de ingeniería de tránsito, teoría de colas y dinámica de fluidos vehiculares, garantiza la robustez, adaptabilidad y eficacia operativa del sistema en diferentes escenarios de tráfico. Su capacidad para responder con precisión a las variaciones en la demanda y composición vehicular, fundamentada en datos precisos de detección en tiempo real, asegurando una mejora sustancial en la movilidad urbana, reducción de impactos ambientales y optimización de la infraestructura vial.

- **OG:** Desarrollar el modelo de tráfico vehicular, basado en Redes Neuronales Artificiales (RNA), que permita reducir, la congestión vehicular en el Jirón Carlos F. Vivanco, distrito de Ayacucho, 2024.

El desarrollo del modelo de tráfico vehicular basado en Redes Neuronales Artificiales (RNA) ha logrado cumplir exitosamente con el objetivo general de reducir la congestión vehicular en el Jirón Carlos F. Vivanco, distrito de Ayacucho, 2024. Este sistema representa una innovación significativa en la gestión del tránsito urbano local, integrando tres componentes fundamentales que trabajan sinérgicamente para optimizar el flujo vehicular. En primer lugar, la arquitectura YOLO (You Only Look Once) implementada ha demostrado una excepcional capacidad para la detección, clasificación y conteo de vehículos bajo las diversas condiciones ambientales y de tráfico características del Jirón Carlos F. Vivanco. En segundo lugar, el proceso de entrenamiento optimizado ha permitido alcanzar un equilibrio ideal entre precisión detectiva y robustez operativa. Finalmente, el algoritmo de optimización semafórica desarrollado que establece una correlación directa y dinámica entre la densidad vehicular detectada y los tiempos de ciclo implementados. La integración de estos tres componentes en un modelo unificado representa una solución holística al problema de congestión vehicular en el Jirón Carlos F. Vivanco mejorando sustancialmente la movilidad urbana y reduciendo el impacto ambiental, así mismo; establece un precedente

metodológico para la implementación de sistemas de transporte inteligente adaptados demostrando que tecnologías avanzadas pueden implementarse exitosamente para resolver problemas cotidianos de movilidad urbana en contextos locales específicos.

5.2. Recomendaciones

- Para mejorar las métricas del equilibrio de conjunto de datos, se recomienda aumentar artificialmente las clases minoritarias mediante técnicas como SMOTE o aplicar transformaciones específicas (rotación, escalado, cambios de iluminación) para multiplicar las instancias existentes. El balanceo de datos mejorará significativamente los rendimientos de precisión, recall, mAP50-95, etc.
- Antes de iniciar el etiquetado, realizar un estudio preliminar del parque automotor local para identificar todas las variantes y subtipos relevantes de vehículos. El etiquetado de vehículos en múltiples perspectivas (frontal, lateral, posterior y diagonal) es esencial para crear sistemas de control semafórico adaptables a cualquier intersección. Esta diversidad de ángulos, combinada con variaciones en elevación, oclusiones parciales y diferentes ángulos de aproximación, permite que el modelo reconozca correctamente los vehículos independientemente de la ubicación y orientación de las cámaras.
- Para mejorar la precisión de las métricas de clasificación vehicular, se recomienda un refinamiento jerárquico de las clases. Esto implica subdividir las categorías actuales en variantes significativas, como clases independientes para mototaxis y motocargas; diferenciación de Pick Ups por tamaño (compactas, medianas, grandes); clasificación de camiones según su configuración de ejes; y categorización de combis rurales por tamaño y ancho (pequeños, medianos, grandes, anchos). Si bien comparten ciertas características, estas subdivisiones son cruciales para una clasificación más precisa.
- Se recomienda una actualización de los valores UCP. Si bien esta investigación adoptó los valores propuestos por GIZ y FIC-UNI en el PDU-Huamanga, es crucial recalibrar las equivalencias para reflejar la actual diversidad vehicular, que incluye una mayor gama de longitudes y dimensiones. El ajuste de los valores UCP debería considerar los patrones de conducción típicos de cada clase de vehículo en la región, más allá de sus dimensiones físicas.

5.3. Trabajos futuros

- Al modelo de análisis de tráfico (clasificación, detección, conteo y optimización de ciclos por densidad) se puede implementar algoritmos que puedan anticipar patrones de tráfico en los próximos 15-30 minutos, permitiendo ajustes proactivos en lugar de reactivos. Así mismo, integrar reconocimiento de peatones y ciclistas: Expandir el modelo para identificar y priorizar usuarios vulnerables de la vía, mejorando la seguridad vial integral.

- Al modelo de análisis de tráfico (clasificación, detección, conteo y optimización de ciclos por densidad) se puede integrar un desarrollo de módulo para peatones, complementando el sistema actual con un módulo dedicado a la detección y cuantificación de flujos peatonales, permitiendo optimizar también los tiempos de cruce para transeúntes, especialmente en zonas de alta afluencia.
- Al modelo de análisis de tráfico (clasificación, detección, conteo y optimización de ciclos por densidad) se puede añadir un módulo de detección de incidentes que permita identificar automáticamente accidentes, vehículos detenidos o comportamientos anómalos que requieran intervención.
- Con el modelo de análisis de tráfico (clasificación, detección, conteo y optimización de ciclos por densidad) y las cámaras ya disponibles, solo se necesitaría un controlador semafórico inteligente que actúe como interfaz entre el modelo analítico y la infraestructura física de semáforos para aplicar dinámicamente los ciclos calculados en la intersección real, transformando así la solución teórica en una aplicación práctica y escalable para la gestión inteligente del tránsito urbano en Ayacucho.
- Una vez que se realice e instale el controlador, se debe realizar una implementación gradual del sistema, se recomienda desplegar el sistema de manera escalonada, comenzando con una fase piloto en la intersección más congestionada del Jirón Carlos F. Vivanco, para posteriormente expandirlo al resto de la vía. Esto permitirá ajustar el modelo a las particularidades de cada intersección y evaluar su impacto real antes de una implementación completa.
- Finalmente después de la instalación de todos los controladores semafóricos, es factible la construcción de una plataforma de monitoreo centralizada, que permita la supervisión en tiempo real del funcionamiento del sistema, facilitando la detección temprana de anomalías y la toma de decisiones para situaciones excepcionales. Enrichiendo la base de datos de entrenamiento con nuevas condiciones y situaciones específicas, incluyendo eventos culturales, festividades y patrones estacionales que generen variaciones significativas en el tráfico.

- Abbas, S. K., Khan, M. U. G., ... Hassan, M. U. (2023). Vision based intelligent traffic light management system using Faster R-CNN. *CAAI Transactions on Intelligence Technology*. <https://doi.org/10.1049/cit2.12309>
- Akçelik, R. (1980). *Time-Dependent Expressions for Delay, Stop Rate and Queue Length at Traffic Signals* (Internal Report N.º AIR 367-1). Australian Road Research Board.
- Akçelik, R., & Besley, M. (2001). Queue-based and time-dependent delay models for signalized intersections. *Transportation Research Record*.
- Apestegui Florentino, Y. I., & Caselli Gismondi, H. E. (2024). Sistema Inteligente de Gestión de Semáforos en Tiempo Real. *Revista Ibérica de Sistemas e Tecnologías de Informação*, 54. <https://doi.org/10.17013/risti.54.69-87>
- Arrieta, K. (2013). *Modelación del tráfico vehicular con el software PTV Vissim - Tramo Bomba El gallo - Bomba El Amparo* [Tesis de pregrado]. Universidad de Cartagena.
- Bank, D., Koenigstein, N., & Giryas, R. (2021). Autoencoders [Versión actualizada publicada el 3 de abril de 2021]. *arXiv preprint arXiv:2003.05991v2*. <https://arxiv.org/abs/2003.05991>
- Becerra, R. (2014). *Modelo Neuronal de Demanda de Transporte en Redes Viales Urbanas* [Tesis Posgrado]. Universidad Nacional de Ingeniería.
- Bisong, E. (2019). Google Colaboratory. En *Building Machine Learning and Deep Learning Models on Google Cloud Platform*. Apress. https://doi.org/10.1007/978-1-4842-4470-8_7
- Brousseau, M., Zangenehpour, S., ... Miranda-Moreno, L. (2013). The impact of waiting time and other factors on dangerous pedestrian crossings and violations at signalized intersections: A case study in Montreal. *Transportation Research Part F: Traffic Psychology and Behaviour*, 21, 8. <https://doi.org/10.1016/j.trf.2013.09.010>
- Brownlee, J. (2020). Failure of Classification Accuracy for Imbalanced Class Distributions. *Machine Learning Mastery*. <https://machinelearningmastery.com/failure-of-accuracy-for-imbalanced-class-distributions/>
- Bull, A. (2003). *Congestión de tránsito: El problema y cómo enfrentarlo*. Comisión Económica para América Latina y el Caribe (CEPAL).
- Caballero Romero, A. (2014). *Metodología integral innovadora para planes y tesis: La metodología del cómo formularlos*. Cengage Learning.
- Cal y Mayor Reyes Spíndola, R., & Cárdenas Grisales, J. (2018). *Ingeniería de tránsito. Fundamentos y aplicaciones* (Novena edición). Alfaomega Grupo Editor.
- Chollet, F., & Allaire, J. (2018). *Deep Learning with R*. Manning Publications.
- Coanqui Apaza, F. Y., Estofanero Yanapa, R. F., & Mamani Condori, H. W. (2022). *Aplicación de inteligencia y visión artificial para la obtención del aforo*

- vehicular* [Tesis para obtener el Título Profesional de Ingeniero Civil]. Universidad Peruana Unión.
- Cordero, M. S. M. (2012). *Los vehículos motorizados privados y el problema de transporte público en los centros históricos: el caso de Cuenca Ecuador* (Artículo técnico N.º 1). Universidad de Cuenca.
- Da Silva, I. N., Spatti, D. H., ... Alves, S. F. d. R. (2017). *Artificial Neural Networks: A Practical Course* (1.ª ed., Vol. 651). Springer International Publishing. <https://doi.org/10.1007/978-3-319-43162-8>
- Duc, Q.-A. N., Kim, T. D., ... Nguyen, V.-N. (2024). Optimizing Traffic Light Control using YOLOv8 for Real-Time Vehicle Detection and Traffic Density. *Proceedings of the 2024 9th International Conference on Integrated Circuits, Design, and Verification (ICDV)*. <https://doi.org/10.1109/ICDV61346.2024.10616901>
- Effective Health Care Program. (2022). *Appendix: Test Performance Metrics*. <https://effectivehealthcare.ahrq.gov/products/test-performance-metrics/appendixes>
- Engineering Notes. (2018). *Highway Capacity: Definition, Importance, Factors and Formula*. <https://www.engineeringenotes.com/transportation-engineering/traffic-engineering/highway-capacity-definition-importance-factors-and-formula/48457>
- Evidentlyai. (2023). *Accuracy vs. precision vs. recall in machine learning: what's the difference?* <https://www.evidentlyai.com/classification-metrics/accuracy-precision-recall>
- Federal Highway Administration. (2006). *Traffic Analysis Toolbox Volume III: Guidelines for Applying Traffic Microsimulation Modeling Software* (inf. téc.). U.S. Department of Transportation. https://ops.fhwa.dot.gov/trafficanalysistools/tat_vol3/sect5.htm
- Federal Highway Administration. (2009). *Manual on Uniform Traffic Control Devices (MUTCD)*. U.S. Department of Transportation. <https://mutcd.fhwa.dot.gov/html/2009/part4/part4e.htm>
- Garber, N. J., & Hoel, L. A. (2020). *Traffic and Highway Engineering* (Sixth edition). Cengage Learning.
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems* (2.ª ed.). O'Reilly Media.
- Gonzales del Valle Romero, G. F., & Neyra Espinoza, W. J. (2022). *Implementación de una red neuronal artificial convolucional para la detección y conteo de vehículos en una sección del estacionamiento de la Universidad Ricardo Palma* [Tesis para optar el título profesional de Ingeniero Electrónico]. Universidad Ricardo Palma.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>

- Google Developers. (2023). *Classification: Accuracy, recall, precision, and related metrics*. <https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall>
- Guerrero-Ibáñez, J., Zeadally, S., & Contreras-Castillo, J. (2018). Sensor Technologies for Intelligent Transportation Systems. *Sensors*, 18(4), 12. <https://doi.org/10.3390/s18041212>
- Highway Capacity Manual. (2016). *A Guide for Multimodal Mobility Analysis* (Sixth Edition). Transportation Research Board.
- Hoogendoorn, S. P., & Bovy, P. H. L. (2001). State-of-the-art of vehicular traffic flow modelling. *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*, 215(4), 15. <https://doi.org/10.1177/095965180121500403>
- IBM Cloud Education. (2020). *AI vs. Machine Learning vs. Deep Learning vs. Neural Networks: What's the Difference?* <https://www.ibm.com/cloud/learn/ai-vs-machine-learning-vs-deep-learning-vs-neural-networks>
- Jiménez, M. (2011). *Sistema adaptativo de control y optimización de tráfico de un corredor vial semaforizado, aplicación ciudad de Medellín* [Tesis de maestría]. Universidad Nacional de Colombia.
- Jocher, G. (2020). *Ultralytics YOLOv5 (7.0)*. <https://doi.org/10.5281/zenodo.3908559>
- Jocher, G., Chaurasia, A., & Qiu, J. (2023). *Ultralytics YOLOv8 (8.0.0)*. <https://github.com/ultralytics/ultralytics>
- Kiran, K. V., Dash, S., & Parida, P. (2024). Vehicle detection in varied weather conditions using enhanced deep YOLO with complex wavelet. *Engineering Research Express*, 6(2). <https://doi.org/10.1088/2631-8695/ad507d>
- Koonce, P., Rodegerdts, L., ... Urbanik, T. (2008). *Traffic Signal Timing Manual* (inf. téc. N.º FHWA-HOP-08-024). Federal Highway Administration. Washington, DC.
- Krivda, V., Petru, J., ... Novak, J. (2021). Use of Microsimulation Traffic Models as Means for Ensuring Public Transport Sustainability and Accessibility. *Sustainability*, 13(5), 13. <https://doi.org/10.3390/su13052709>
- Lasse, R. (2018). *Inteligencia artificial: 101 cosas que debes saber hoy sobre nuestro futuro*. Alienta Editorial.
- Li, L., Lv, Y., & Wang, F. (2021). Traffic Signal Timing via Deep Reinforcement Learning. *IEEE/CAA Journal of Automatica Sinica*, 8(6), 10. <https://doi.org/10.1109/JAS.2021.1003952>
- Lin, C.-J., & Lee, C.-M. (2024). Real-Time Vehicles Detection with YOLOv8. *11th IEEE International Conference on Consumer Electronics - Taiwan (ICCE-Taiwan)*. <https://doi.org/10.1109/ICCE-Taiwan62264.2024.10674607>
- Lu, X.-Y., Lee, J., ... Shladover, S. E. (2014). Freeway Micro-simulation Calibration: Case Study Using Aimsun and VISSIM with Detailed Field Data [Word Count: 7466]. *93rd Annual Meeting of the Transportation Research Board*, 17.

- Luna Gonzalez, J. (2018). *Tipos de aprendizaje automático*. <https://medium.com/soldai/tipos-de-aprendizaje-autom%C3%A1tico-6413e3c615e2>
- Manual of Traffic Signal Design* (2.^a ed.). (1990). Institute of Transportation Engineers. https://www.webpages.uidaho.edu/niatt_labmanual/Chapters/signaltimingdesign/professionalpractice/PedestrianCrossingTimeMinimumGreen.htm
- May, A. D. (1990). *Traffic Flow Fundamentals*. Prentice Hall.
- Minaee, S., Boykov, Y., ... Terzopoulos, D. (2021). Image Segmentation Using Deep Learning: A Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(7), 19. <https://doi.org/10.1109/TPAMI.2021.3059968>
- Montoya Calderón, A. Y. (2021). *Diseño de un controlador descentralizado adaptable al sistema de semaforización de Lima Metropolitana para la optimización de tiempos de los ciclos semaforicos en tiempo real* [Tesis para optar por el título profesional de Ingeniero Mecatrónico]. Pontificia Universidad Católica del Perú.
- Municipalidad Provincial de Huamanga. (2020). *Plan de Desarrollo Urbano de la Ciudad de Ayacucho 2020-2030* (Plan de Desarrollo Urbano). Ministerio de Vivienda, Construcción y Saneamiento.
- Municipalidad Provincial de Huamanga. (2022). *Plan de Movilidad Urbana Sostenible Huamanga* (Plan de Movilidad). Ministerio de Transportes y Comunicaciones.
- Naithani, A., & Jain, V. (2024). Real-Time Crossroad Traffic Light Management. *8th International Symposium on Innovative Approaches in Smart Technologies, ISAS 2024 - Proceedings*. <https://doi.org/10.1109/ISAS64331.2024.10845613>
- National Association of City Transportation Officials. (2025). *Signal Cycle Lengths*. <https://nacto.org/publication/urban-street-design-guide/intersection-design-elements/traffic-signals/signal-cycle-lengths/>
- Nizama Yamunaque, D. A. (2022). *Sistema de detección y clasificación vehicular basado en redes neuronales de aprendizaje profundo* [Tesis para obtener el título profesional de Ingeniero Civil]. Universidad Nacional de Ingeniería.
- Núñez, F. (2016). *Diseño de un sistema de reconocimiento automático de matrículas de vehículos mediante una red neuronal convolucional* [Tesis Doctoral no publicada]. Universitat Oberta de Catalunya.
- Papageorgiou, M., & Messmer, A. (1991). Dynamic Network Traffic Assignment and Route Guidance via Feedback Regulation [In: In-Vehicle Information Systems: Modeling Traffic Networks and Behavioral Considerations]. *Transportation Research Record*, 1306, 10.
- Pawade, P., Parkhi, V., ... Nikam, V. (2024). Self-Adaptive Traffic Density Based Management System. *2024 IEEE International Conference on Blockchain and Distributed Systems Security (ICBDS)*. <https://doi.org/10.1109/ICBDS61829.2024.10837297>
- Pishue, B. (2020). *2020 INRIX Global Traffic Scorecard* (Technical Report). INRIX.

- Pudaruth, S., Boodhun, I. M., & Onn, C. W. (2024). Reducing Traffic Congestion Using Real-Time Traffic Monitoring with YOLOv8. *International Journal of Advanced Computer Science and Applications*, 15(10). <https://doi.org/10.14569/IJACSA.2024.01510109>
- Rakha, H., & Farzaneh, M. (2019). Computing optimum traffic signal cycle length considering vehicle delay and fuel consumption. *European Transport Research Review*, 11(1), 19. <https://doi.org/10.1186/s12544-019-0345-9>
- Ramachandran, P., Zoph, B., & Le, Q. V. (2017). Searching for activation functions. *arXiv preprint*. <https://arxiv.org/abs/1710.05941>
- Redmon, J., Divvala, S., ... Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 18. <https://doi.org/10.1109/CVPR.2016.91>
- Roess, R. P., Prassas, E. S., & McShane, W. R. (2019). *Traffic Engineering* (Fifth edition). Pearson.
- Ruiz-Choque, M., Soto, L., ... Reategui, A. (2023). Intelligent System to Reduce Vehicle Congestion on Intense Traffic in Areas of Lima City. *8th International Conference on Intelligent Technologies (ICIT 2023)*, 1031. https://doi.org/10.1007/978-981-97-3859-5_35
- Russell, B. C., Torralba, A., ... Freeman, W. T. (2008). LabelMe: A Database and Web-Based Tool for Image Annotation. *International Journal of Computer Vision*, 77, 16. <https://doi.org/10.1007/s11263-007-0090-8>
- Sivaganesan, D., Kumar, S. B., ... Rashmitha, G. (2024). Optimization of Vehicular Congestion Control in Traffic Signals using YOLO algorithm. *2024 International Conference on Smart Systems for Electrical, Electronics, Communication and Computer Engineering (ICSSEEC)*. <https://doi.org/10.1109/ICSSEEC61126.2024.10649430>
- Smith, M., & Mounce, R. (2011). A splitting rate model of traffic re-routeing and traffic control. *Transportation Research Part B: Methodological*, 45(9), 20. <https://doi.org/10.1016/j.trb.2011.05.014>
- Szeliski, R. (2022). *Computer Vision: Algorithms and Applications* (2.^a ed.). Springer Nature. <https://szeliski.org/Book/>
- The Data Scientist. (2023). *What is the F-1 measure and why is it useful for imbalanced class problems?* <https://thedata scientist.com/f-1-measure-useful-imbalanced-class-problems/>
- TRANSITEMOS, F. (2017). *Aspectos Negativos de la Congestión Vehicular: Impacto social y económico* (Technical Report). Fundación TRANSITEMOS.
- Turner, S., Vallyon, C., ... Hodgson, S. (2008). *Reducing Pedestrian Delays at Traffic Signals*. IPENZ Transportation Group Conference. https://www.researchgate.net/publication/335149750-Reducing_Pedestrian_Delays_at_Traffic_Signals

- Valencia Gutiérrez, A. A., Chavarry Vallejos, C. M., ... Laos Laura, X. A. (2023). *El ABC de la investigación para ingenieros* (Primera edición) [Tiraje: 100 ejemplares]. Editorial Navegante.
- Vaswani, A., Shazeer, N., ... Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 18.
- Vector ITC. (2018). Inteligencia Artificial. Pasado, presente y futuro. *Vector ITC*, 13.
- Wang, C., Shang, Q., ... Zhang, W. (2025). Traffic congestion recognition based on convolutional neural networks in different scenarios. *Engineering Applications of Artificial Intelligence*, 148. <https://doi.org/10.1016/j.engappai.2025.110372>
- Wang, Y., Zhang, X., ... Sun, J. (2022). Anchor DETR: Query Design for Transformer-Based Detector. *Proceedings of the AAAI Conference on Artificial Intelligence*, 36(3), 18. <https://ojs.aaai.org/index.php/AAAI/article/view/20158>
- Webster, F. V. (2004). *Traffic Signal Settings* (inf. téc. N.º 39). Road Research Laboratory. London, Her Majesty's Stationery Office.
- Xu, S., Zhang, M., ... Zhong, Y. (2024). YOLO-HyperVision: A vision transformer backbone-based enhancement of YOLOv5 for detection of dynamic traffic information. *Egyptian Informatics Journal*, 27. <https://doi.org/10.1016/j.eij.2024.100523>
- Yamashita, R., Nishio, M., ... Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, 9(4), 18. <https://doi.org/10.1007/s13244-018-0639-9>
- Yu, Y., Si, X., ... Zhang, J. (2019). A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures. *Neural Computation*, 31(7), 35. https://doi.org/10.1162/neco_a_01199
- Zegeer, C., & Deen, R. (1978). Green-Extension Systems at High-Speed Intersections. *ITE Journal*, 48(11), 19-24.
- Zhang, Y., Fu, C., & Hu, L. (2014). Yellow light dilemma zone researches: a review. *Journal of Traffic and Transportation Engineering (English Edition)*, 1(5), 14. [https://doi.org/10.1016/S2095-7564\(15\)30280-4](https://doi.org/10.1016/S2095-7564(15)30280-4)
- Zhang, Y., & Su, R. (2021). An optimization model and traffic light control scheme for heterogeneous traffic systems. *Transportation Research Part C: Emerging Technologies*, 124. <https://doi.org/10.1016/j.trc.2020.103081>

6. ANEXOS

6.1. Panel fotográfico-instalación de cámaras de investigación



Figura 267: Instalación de las cámaras de investigación
Fuente: Imagen propia




Figura 268: Preparación del camión grua
Fuente: Imagen propia




Figura 269: Despliegue del brazo hidráulico
Fuente: Imagen propia



Figura 270: Despliegue del brazo hidráulico, vista principal
Fuente: Imagen propia



Figura 271: Supervisión de la instalación.
Fuente: Imagen propia




Figura 272: Instalación de los dispositivos a la caja de control electrico
Fuente: Imagen propia



Figura 273: Montaje del brazo rígido de soporte
Fuente: Imagen propia



Fuente: Imagen propia



Fuente: Imagen propia

6.2. Matriz de consistencia y operacionalización - formatos de campo y documentación

La matriz de consistencia y operacionalización de variables, así como los formatos en campo para el control de los ciclos semafóricos y la documentación usada en la investigación, se detallan a continuación:

Cuadro : Matriz de consistencia.

Problemas principal	Objetivos general	Hipótesis general	Variables	Metodología
¿De qué manera el modelo de tráfico vehicular basado en Redes Neuronales Artificiales (RNA) ,reduce la congestión vehicular en el Jirón Carlos F. Vivanco, distrito de Ayacucho ,2024?	Desarrollar el modelo de tráfico vehicular basado en Redes Neuronales Artificiales (RNA) que permita reducir la congestión vehicular en el Jirón Carlos F. Vivanco distrito de Ayacucho 2024.	El modelo de tráfico vehicular basado en Redes Neuronales Artificiales reduce significativamente la congestión vehicular en el Jirón Carlos F. Vivanco distrito de Ayacucho 2024.	Independiente X: Modelo de tráfico vehicular <u>Dimensiones</u> – Arquitectura del modelo – Diseño del modelo – Entrenamiento del modelo – Resultados e implementación del modelo Dependiente Y: Congestión vehicular <u>Dimensiones</u> – Índice de la congestión – Evaluación de la congestión – Análisis de la congestión – Comparación con métodos tradicionales	Método,Orientación, Enfoque: – Deductivo,aplicada, cuantitativo Intrumento de recolección de datos, Tipo, Nivel: – Proelectiva, explicativo, aplicativo Diseño, Estudio del diseño: – No experimental, transversal, prospectivo ,Estudio de Cohortes Población: – La población del estudio está constituida por 5,000 imágenes de vehículos capturadas en el Jirón Carlos F. Vivanco, Ayacucho. Estas imágenes fueron obtenidas mediante observación sistemática no participante. Muestra: – La muestra será intencional, seleccionando imágenes que representen adecuadamente la variabilidad de condiciones de tráfico. Se selecciono una muestra representativa de 3000 imágenes. Técnica: – Observación sistemática no participante Instrumento: – Cámaras IMOU
Problemas específico	Objetivos específico	Hipótesis específico		
¿Cómo el diseño del modelo basado en Redes Neuronales Artificiales (RNA) permite ajustar una arquitectura para la detección,clasificación y conteo eficiente de vehículos en condiciones heterogéneas, que incluyen tráfico variable, diversas condiciones ambientales (precipitaciones, iluminación solar variable,sombras proyectadas y entornos nocturnos con visibilidad limitada?	Desarrollar el diseño del modelo basado en Redes Neuronales Artificiales (RNA) que permita ajustar una arquitectura para la detección, clasificación y conteo eficiente de vehículos en condiciones heterogéneas que incluyen tráfico variable diversas condiciones ambientales (precipitaciones, iluminación solar variable, sombras proyectadas) y entornos nocturnos con visibilidad limitada.	El diseño del modelo basado en Redes NeuronalesArtificiales (RNA) permite ajustar una arquitectura para la detección,clasificación y conteo de vehículosencondiciones heterogeneas, queincluyentráficovariable,diversascondicionesambientales(precipitaciones, iluminación solar variable, sombras proyectadas) y en entornos nocturnos con limitada visibilidad.		
¿En qué medida el entrenamiento del modelo basado en Redes Neuronales Artificiales (RNA) permite alcanzar un equilibrio óptimo entre la precisión en la detección, la exhaustividad en el reconocimiento de vehículos y la robustez contra el sobreajuste?	Simular el entrenamiento del modelo basado en Redes Neuronales Artificiales (RNA) para lograr un equilibrio óptimo entre la precisión en la detección la exhaustividad en el reconocimiento de vehículos y la robustez contra el sobreajuste.	El entrenamiento del modelo basado en Redes Neuronales Artificiales (RNA) logra un equilibrio óptimo entre la precisión en la detección la exhaustividad en el reconocimiento de vehículos y la robustez contra el sobreajuste.		
¿De qué manera la implementación del modelo basado en Redes Neuronales Artificiales (RNA) permite desarrollar un algoritmo que optimice la duración de los ciclos semafóricos en función de la densidad vehicular bajo condiciones variables de tráfico?	Determinar como la implementación del modelo basado en Redes Neuronales Artificiales (RNA) permite desarrollar un algoritmo que optimice la duración de los ciclos en función de la densidad vehicular bajo condiciones variables de tráfico.	La implementación del modelo basado en Redes Neuronales Artificiales (RNA) permite desarrollar un algoritmo, que optimiza la duración de los ciclos en función de la densidad vehicular bajo condiciones variables de tráfico.		

Fuente: Elaboración propia.

Cuadro : Matriz de Operacionalización de variables.

Variable	Definición conceptual	Dimensiones	Indicadores	Unidad de medida
Independiente (X): Modelo de tráfico vehicular	Un modelo de tráfico vehicular es una representación simplificada y matemática de la realidad del flujo de vehículos en una vía o red vial. Este modelo busca predecir el comportamiento del tráfico bajo diferentes condiciones, como la densidad de vehículos, la velocidad, y el flujo vehicular.	1. Arquitectura del modelo	- Número de capas de la RNA	Conteo (n)
		2. Diseño del modelo	-Tipo de capas	Categórico
			-Tamaño de las capas	Conteo (n)
			-Función de activación	Categórico
			-Tasa de aprendizaje	(%)
			-Número de épocas de entrenamiento	Conteo (n)
		3. Entrenamiento del modelo	-Momento (momentum)	(%)
			-Factor de decaimiento del aprendizaje	(%)
			-Algoritmo de optimización y técnicas de regularización	Categórico
			-Estrategias de aumento de datos y esquema de aprendizaje	Categórico
			-Precisión, pérdida en la validación y entrenamiento, sobreajuste	(%)
			-Tiempo total de entrenamiento	(min)
			-Curva de aprendizaje	(Gráfico)
			-Pesos del modelo	Matriz
			-Bias del modelo	Vector
		4. Resultados e implementación del modelo	-Plataforma de Software	(%)
			-Entorno de Simulación	(sistemas)
			-Predicción de la congestión	(veh/tipo)
			-Optimización de los ciclos semafóricos	(segundos)
Dependiente (Y): Congestión vehicular	El congestionamiento vehicular se refiere a una condición en la que el flujo de vehículos en una vía o red vial se satura, lo que resulta en una disminución significativa de la velocidad, incrementos en los tiempos de viaje y, en general, una disminución en la eficiencia del sistema de transporte. Esta situación se produce cuando la demanda de espacio en las vías supera la capacidad disponible, generando atascos o embotellamientos.	1. Índice de la congestión	-Número de vehículos por tipo	(veh/tipo)
		2. Evaluación de la congestión	-Velocidad promedio de los vehículos	(km/h)
			-Velocidad máxima registrada	(km/h)
			-Velocidad mínima registrada	(km/h)
		3. Análisis de la congestión	-Reducción del tiempo de viaje y mejora en el flujo vehicular	(veh/tiempo)
		4. Comparación con métodos tradicionales	-Reducción de tiempo	(%)
			-Precisión de detección	(%)
			-Consumo de recursos	(%)

Fuente: Elaboración propia.

Fecha: 08 de Abril de 2025 : Data de Campo.

Datos de Campo - Semáforos

Ciclo Total

[illegible]



Ayacucho, 21 de Octubre del 2024

CARTA N° 000050-2024-MPH/49.51 [2461209.005]

SEÑOR(A) : DIEGO OMAR, TENORIO HUARANCCA.
BACHILLER EN CIENCIAS DE LA INGENIERÍA CIVIL - UNSCH.
ASUNTO : Autorización de instalación de Cámaras de Vigilancia.
REFERENCIA : SOLICITUD, REG. N° 2461209.
INFORME N° 000216-2024-MPH/28 [2461209.004].
INFORME N° 000021-2024-MPH/28 [2461209.003].

De mi consideración:

Por la presente reciba un cordial saludo de nuestra Autoridad Edil, el Dr. Juan Carlos Arango Claudio, así mismo de la Sub Gerencia de Tránsito y Seguridad Vial de la Municipalidad Provincial de Huamanga; y a su vez mencionarle que vista la solicitud, Reg. N° 2461209; sobre **PERMISO PARA LA INSTALACIÓN DE CÁMARAS DE VIGILANCIA EN LA INTERSECCIÓN DEL JR. F. VIVANCO Y EL ÓVALO PUENTE NUEVO, CON FINES DE INVESTIGACIÓN**, durante el periodo del 23 de octubre hasta el 31 de diciembre del año 2024, para lo cual la Unidad de Tecnologías de Información y Comunicación, realizó la evolución de las características de las cámaras y determino que si cumplen con las características para dicho fin. En vista a ello, la solicitud presentada **ES VIABLE**, debiendo cumplir las recomendaciones del **INFORME N° 000021-2024-MPH/28 [2461209.003]**, los cuales son:

- Los equipos en mención deberán ser instalados sin perjudicar la visión de la cámara ya pre existente perteneciente a la Sub gerencia de Seguridad ciudadana.
- El personal que realizará los trabajos de instalación, configuración y puesta en funcionamiento deberá cumplir con todas las medidas de seguridad. (Casco, guantes dieléctricos, lentes y arnés de seguridad).
- Se recomienda una vez terminado los trabajos de investigación el retiro de las cámaras y todo el equipo utilizado.
- Se recomienda dejar un DEMO del software y/o aplicativo de trabajo en bien de la Municipalidad Provincial de Huamanga.

ANEXO:

- Copia del INFORME N° 000216-2024-MPH/28 [2461209.004].
- Copia del INFORME N° 000021-2024-MPH/28 [2461209.003].

Sin otro particular, me suscribo de usted.

Atentamente,

Firmado Digitalmente por:
WILBER RAFAEL SUAREZ VILLARROEL





SUB GERENTE
SUBGERENCIA DE TRANSITO Y SEGURIDAD VIAL





MUNICIPALIDAD PROVINCIAL DE HUAMANGA
"CAPITAL DE LA EMANCIPACIÓN HISPANOAMERICANA - LEY N° 24682"
"Año del Bicentenario, de la consolidación de nuestra Independencia, y de la conmemoración de las heroicas batallas de Junín y Ayacucho"



Firmado digitalmente por:
CASTRO RUA Nils Ahmed FAU
20143137296 soft
JEFE
Motivo: Soy el autor del documento
Fecha: 21/10/2024 12:23:31-0500



INFORME N° 000216-2024-MPH/28 [2461209.004]

A : WILBER RAFAEL SUAREZ VILLARROEL
SUB GERENTE
SUBGERENCIA DE TRANSITO Y SEGURIDAD VIAL
DE : NILS AHMED CASTRO RUA
JEFE
UNIDAD DE TECNOLOGIAS DE INFORMACION Y COMUNICACION
ASUNTO : REMITO EVALUACIÓN DE CARACTERÍSTICAS DE CÁMARAS DE
VIGILANCIA
REFERENCIA :
FECHA : Ayacucho, 21 de Octubre del 2024

Es grato dirigirme a usted para saludarlo cordialmente y vistos los documentos de referencia y antecedentes, me permito por medio del presente informar lo siguiente:

Que, teniendo la necesidad de contar con una evaluación de las cámaras de vigilancia que se pretenden instalar en las inmediaciones del óvalo del Puente Nuevo, esto con fines de investigación solicitada por el sr. Diego Omar Tenorio Huarancca; por lo que se ha derivado dicha evaluación al ing. Edwin Cusihuaman para el informe pertinente.

Asimismo precisar que el personal designado se ha reunido con el interesado y que luego de las explicaciones y de los documentos adjuntos, se presenta el Informe de Evaluación de características de cámaras de vigilancia para trabajos de investigación, con el siguiente detalle: Informe N° 0021-2024-MPH/28-CAE, continuando con el mismo número de expediente 2461209, el que remito para los fines consiguientes y tener en cuenta las recomendaciones del mencionado informe.

Es cuanto informo a Ud para su conocimiento y fines pertinentes.

Atentamente.

Firmado Digitalmente por:
NILS AHMED CASTRO RUA
JEFE
UNIDAD DE TECNOLOGIAS DE INFORMACION Y COMUNICACION





INFORME N° 000021-2024-MPH/28-CAE [2461209.003]

A : NILS AHMED CASTRO RUA
JEFE
UNIDAD DE TECNOLOGIAS DE INFORMACION Y COMUNICACION
DE : EDWIN CUSIHUAMAN AGUILAR
INGENIERO DE INFRAESTRUCTURA DE TIC
UNIDAD DE TECNOLOGIAS DE INFORMACION Y COMUNICACION
ASUNTO : EVALUACIÓN DE CARACTERÍSTICAS DE CÁMARAS DE VIGILANCIA PARA TRABAJOS DE INVESTIGACION.
REFERENCIA :
FECHA : Ayacucho, 21 de Octubre del 2024

Mediante el presente, me dirijo a usted, en relación al **INFORME N°000244-MPH/49.51[2461209.002]** y **SOLICITUD** con numero de Registro 2461209 donde se **SOLICITA LA INSTALACIÓN DE CÁMARAS DE VIGILANCIA Y USO TEMPORAL DE LA CASETA DE SERENAZGO CON FINES DE ESTUDIO**, se detalla lo siguiente:

- Se realizo la verificaciones a los equipo presentados como propuesta por el Sr. Diego Omar Tenorio Hurancca a ser instalados los cuales **CUMPLEN** con las características según el diseño de los trabajos a realizar según los fines de estudio mencionados en el documento de solicitud.

Ítem	Marca	Modelo	Tipo	Descripción
1	IMOU		CÁMARA	CÁMARA IP 5 mpx
2	S/M	S/M1	Pedestal 1.5 m	Pedestal de cámara

- Los equipos en mención y según la solitud serán instalados en el Poste de seguridad Ciudadana ubicado entre los cruces de Jr. Carlos F. Vivanco y Ovalo de Puente nuevo.
- La instalación de las nuevas cámaras será de manera independiente a la red existente de Seguridad Ciudadana de tal manera que no perjudique en ningún sentido a la red pre existente.
- Se deberá tener en cuenta la instalación de una toma eléctrica en el gabinete para el correcto funcionamiento de los equipos a instalar.
- Se deberá tener en cuenta la instalación de una toma eléctrica en el Observatorio ya que no se cuenta con una toma eléctrica de acceso en el primer nivel del observatorio para los trabajos de investigación que se realizaran dentro del pedido mencionado en la solicitud del 23/100/2024 al 31/12/2024.

Recomendaciones

- Los equipos en mención deberán ser instalados sin perjudicar la visión de la cámara ya pre existente perteneciente a La Sub Gerencia de Seguridad Ciudadana.
- El personal que realizará los trabajos de instalación, configuración y puesta en funcionamiento deberá cumplir con todas medidas se seguridad. (casco, guates dialecticos, lentes y arnés de seguridad).
- Se recomienda una vez terminado los trabajos de investigación el retiro de las cámaras





y todo el equipo utilizado.

- Se recomienda dejar un DEMO del software y/o aplicativo de trabajo en bien de la Municipalidad Provincial y futuros proyectos a realizar.

Es todo cuanto cumplo con informar a usted, para su conocimiento y demás fines.

Atentamente,

Firmado Electrónicamente por:
EDWIN CUSIHUAMAN AGUILAR
INGENIERO DE INFRAESTRUCTURA DE TIC
UNIDAD DE TECNOLOGIAS DE INFORMACION Y COMUNICACION





MUNICIPALIDAD PROVINCIAL DE HUAMANGA
"CAPITAL DE LA EMANCIPACIÓN HISPANOAMERICANA - LEY N° 24682"
"Año del Bicentenario, de la consolidación de nuestra Independencia, y de la conmemoración de las heroicas batallas de Junín y Ayacucho"



Firmado digitalmente por:
SUAREZ VILLARROEL WILBER RAFAEL
FIR 28605391 hard
SUB GERENTE
Motivo: Soy el autor del documento
Fecha: 18/10/2024 14:09:34-0500



INFORME N° 000244-2024-MPH/49.51 [2461209.002]

A : NILS AHMED CASTRO RUA
JEFE
UNIDAD DE TECNOLOGIAS DE INFORMACION Y COMUNICACION
DE : WILBER RAFAEL SUAREZ VILLARROEL
SUB GERENTE
SUBGERENCIA DE TRANSITO Y SEGURIDAD VIAL
ASUNTO : Solicito Evaluación de Características de Cámaras de Vigilancia.
REFERENCIA : SOLICITUD, REG N° 2461209.
FECHA : Ayacucho, 18 de Octubre del 2024

Tengo el agrado de dirigirme a usted, con la finalidad de saludarlo cordialmente a nombre de la Sub Gerencia de Tránsito y Seguridad Vial y, a la vez, en atención al documento de la referencia, presentado por el señor DIEGO OMAR TENORIO HUARANCCA, Bachiller en Ciencias de la Ingeniería Civil, de la Universidad Nacional de San Cristóbal de Huamanga, quien solicita permiso para la instalación de cámaras de vigilancia en la intersección del Jr. F. Vivanco y el Óvalo Puente Nuevo, con fines de investigación. En vista a ello **SOLICITO EVALUACIÓN DE CARACTERÍSTICAS DE CÁMARAS DE VIGILANCIA**, toda vez que la instalación está prevista para el día martes 22 de octubre del año 2024 y para conceder dicho permiso se necesita la evaluación de las características de las 02 cámaras que se pretende instalar, mismas que deben ser adecuadas para dicho fin.

Es todo cuanto comunico a usted para su conocimiento y atención oportuna.

Atentamente,

Firmado Digitalmente por:
WILBER RAFAEL SUAREZ VILLARROEL
SUB GERENTE
SUBGERENCIA DE TRANSITO Y SEGURIDAD VIAL



- Ne placez pas l'appareil dans un lieu exposé à l'humidité, à la poussière, à une chaleur ou un froid extrême, à de forts rayonnements électroniques, ou à des conditions d'éclairage instables.
- Ne travaillez pas l'appareil près d'une source de chaleur telle qu'un radiateur, un chauffage, une chaudière, ou tout autre dispositif générant de la chaleur afin d'éviter les risques d'incendie.
- Empêchez aux liquides de couler sur l'appareil afin d'éviter d'endommager les composants internes.
- Installez l'appareil horizontalement ou sur une surface stable afin de l'empêcher de tomber.
- Installez l'appareil dans un lieu bien ventilé et ne bloquez pas la ventilation de l'appareil.
- Ne démontez pas l'appareil de façon arbitraire.
- Au cours du transport, du stockage et de l'installation de l'appareil, évitez de le soumettre à de fortes contraintes, à des vibrations violentes ou à une immersion. L'emballage complet est résistant aux chocs pendant le transport.
- Utilisez l'emballage d'usine ou équivalent pour le transport.

Batterie

Un réseau de batterie faible affecte le fonctionnement du RTC, qui se réinitialisera à chaque redémarrage. Lorsque la batterie doit être remplacée, un message de journal apparaît dans le rapport du serveur du produit. Pour plus d'informations sur le rapport du serveur, consultez les pages de configuration du produit ou contactez l'assistance Imou.



AVERTISSEMENT

- Risque d'explosion si la batterie est remplacée de façon incorrecte.
- Remplacez la batterie uniquement par une batterie recommandée par Imou.
- Éliminez les batteries usagées conformément aux réglementations locales ou aux instructions du fabricant de la batterie.

Español(España)

Advertencias y precauciones de seguridad importantes

En este capítulo se describe el contenido que cubre la manipulación correcta del dispositivo, la prevención de riesgos y la prevención de daños materiales. Lea detenidamente este contenido antes de usar el dispositivo, siga cuando lo utilice y consérvelo para consultas futuras.

Instrucciones de seguridad

Las siguientes palabras de advertencia con un significado definido podrían aparecer en la guía.

Palabras de advertencia	Significado
PELIGRO	Indica un riesgo potencial alto que, si no se evita, resultará en muerte o lesiones graves.
ADVERTENCIA	Indica un riesgo potencial medio o bajo que, si no se evita, podría resultar en lesiones leves o moderadas.
PRECAUCIÓN	Indica un riesgo potencial que, si no se evita, podría resultar en daños materiales, pérdida de datos, rendimiento menor o resultados impredecibles.
CONSEJOS	Ofrece métodos para ayudarle a resolver un problema o ahorrar tiempo.
NOTA	Proporciona información adicional como vínculos y complementos para el texto.

Requisitos de seguridad

- Cumpla las normas locales de seguridad eléctrica para garantizar que la tensión sea estable y cumpla los requisitos de alimentación eléctrica del dispositivo.

- Transporte, utilice y almacene el dispositivo bajo las condiciones de humedad y temperatura permitidas. Consulte las especificaciones técnicas correspondientes del dispositivo para la temperatura y humedad operativas específicas.
- No coloque el dispositivo en un lugar expuesto a humedad, polvo, calor o frío extremos, radiaciones electrónicas fuertes o condiciones de iluminación inestables.
- No instale el dispositivo en un lugar cerca de fuentes de calor, como radiadores, calentadores, hornos u otros dispositivos generadores de calor, para evitar un incendio.
- No deje que entre líquido en el dispositivo para evitar daños en los componentes internos.
- Instale el dispositivo horizontalmente o instálelo sobre un lugar estable para evitar que caiga.
- Instale el dispositivo en un lugar bien ventilado y no obstruya la ventilación.
- No desmonte de forma arbitraria el dispositivo.
- Evite las presiones excesivas, las vibraciones violentas y moje el dispositivo durante el transporte, almacenamiento e instalación. Es necesario utilizar el embalaje completo durante el transporte.
- Utilice el embalaje de fábrica o uno equivalente para transportarlo.

Pilas

La baja batería afecta al funcionamiento del RTC, provocando que se restablezca cada vez que recibe alimentación. Cuando sea necesario sustituir las pilas, aparecerá un mensaje de registro en el informe de servicios del producto. Para más información acerca del informe de servicio, consulte las páginas de configuración del producto o póngase en contacto con el departamento de soporte de Imou.



ADVERTENCIA

- Riesgo de explosión si se sustituyen incorrectamente las pilas.
- Sustitúyalas únicamente por pilas idénticas o pilas recomendadas por Imou.
- Elimine las pilas gastadas en conformidad con la normativa local o las instrucciones del fabricante de las pilas.

Deutsch



Wichtige Sicherheits- und Warnhinweise

Dieses Kapitel beschreibt die Inhalte zum richtigen Umgang mit dem Gerät, zur Verhütung von Gefahren und zur Vermeidung von Sachschäden. Lesen Sie dieses Kapitel sorgfältig durch, bevor Sie das Gerät verwenden, halten Sie die Anweisungen bei der Verwendung ein und bewahren Sie diese Anleitung zum späteren Nachlesen gut auf.

Sicherheitshinweise

Die folgenden kategorisierten Signalwörter mit definierter Bedeutung können in der Kurzanleitung verwendet werden.

Signalwörter	Bedeutung
GEFAHR	Weist auf ein hohes Gefahrenpotential hin, das, wenn es nicht vermieden wird, zum Tod oder zu schweren Verletzungen führt.
WARNUNG	Weist auf eine mittlere oder geringe potenzielle Gefahr hin, die, wenn sie nicht vermieden wird, zu leichten oder mäßigen Verletzungen führen kann.
VORSICHT	Weist auf ein potenzielles Risiko hin, das, wenn es nicht vermieden wird, zu Sachschäden, Datenverlust, geringerer Leistung oder unvorhersehbaren Ergebnissen führen kann.
TIPPS	Stellt Methoden bereit, mit denen Sie ein Problem lösen oder Zeit sparen können.
HINWEIS	Bietet zusätzliche Informationen als Schwerpunkt und Ergänzung zum Text.



01

MUNICIPALIDAD PROVINCIAL
DE HUAMANGA
Centro de Atención al Vecino

16 OCT 2024

Reg. N°: 2461209

N° Folios: 06 Hora: 9:41

Pase a: S. G. T. VIAL

**SOLICITO: PERMISO PARA LA
INSTALACIÓN DE CÁMARAS DE
VIGILANCIA Y USO TEMPORAL DE LA
CASETA DE SERENAZGO CON FINES
DE INVESTIGACIÓN.**

SEÑOR ALCALDE DE LA MUNICIPALIDAD PROVINCIAL DE HUAMANGA

Yo, **TENORIO HUARANCCA, DIEGO OMAR**
identificado con DNI N°: **70029569**, tesista de la Universidad
Nacional San Cristóbal de Huamanga, bachiller en Ciencias
de la Ingeniería Civil, egresado de la escuela profesional de
Ingeniería Civil de la UNSCH, con domicilio: Av. Los Incas
#264 en el distrito de San Juan Bautista-Ayacucho. Ante
usted respetuosamente me presento y expongo:

Que, recurro a su respetable despacho con la finalidad, se me
permita la instalación de dos cámaras de vigilancia, en la intersección del Jr. Carlos F. Vivanco y el Óvalo de
Puente Nuevo, el día **MARTES 22 DE OCTUBRE A HORAS 9 AM HASTA LAS 12 PM**, del presente mes,
así mismo; el uso temporal de la caseta de serenazgo, ubicado en el óvalo de puente nuevo, durante el periodo
de 23 de Octubre hasta el 31 de diciembre del presente año, cumpliendo el horario de investigación de 8 am a
6 pm, siendo las videograbaciones obtenidas; datos fundamentales para la elaboración de mi investigación
(entrenamiento de mis redes neuronales artificiales).

POR LO EXPUESTO

Ruego a usted acceder a mi solicitud, por ser justa y necesaria.

ADJUNTO:

- Fotografías de la ubicación, donde se situarán las cámaras de vigilancia y la caseta de serenazgo.
- Documento Nacional de Identidad DNI.
- Copia de Grado Académico de Bachiller en Ciencias de la Ingeniería Civil.
- Carta de aceptación de mi docente asesor, para poder realizar mi investigación.
- Declaración Jurada.

Ayacucho, 16 de octubre de 2024

[Firma manuscrita]

TENORIO HUARANCCA, DIEGO OMAR
DNI N° : 70029569
CEL:938136187

MUNICIPALIDAD PROVINCIAL - HUAMANGA


17 OCT 2024

Reg. N°: FeNo:

Hora: Pasa:



Ubicación de las cámaras de vigilancia para fines de investigación, en el Jirón Carlos F. Vivanco-Óvalo de Puente Nuevo.



Ubicación de la caseta de Serenazgo a donde se dirigirá todo el cableado.



ACTA DE SUSTENTACIÓN DE TESIS N° 016-2025-FIMGC

PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO CIVIL

En la Universidad Nacional de San Cristóbal de Huamanga, en la ciudad de Ayacucho, en cumplimiento a la **Resolución Decanal No 139-2025-FIMGC-D**, a los **diecisiete días del mes de junio de 2025**, siendo las **10:00 a.m.**, reunidos en el **Auditorio de la Escuela Profesional de Ingeniería Civil**, bajo la presidencia del **Mg. Ing. José Ernesto ESTRADA CÁRDENAS**, y los miembros: **MSc. Ing. Moisés Nico BARBARAN ORIUNDO**, **MSc. Ing. Rocky Giban AYALA BIZARRO** y **Dr. Ing. Hemerson LIZARBE ALARCÓN**, actuando como secretario docente el **MSc. Ing. Saul Walter RETAMOZO FERNÁNDEZ**, para proceder a la sustentación de tesis para optar el **Título Profesional de Ingeniero Civil**, del bachiller en Ciencias de la Ingeniería Civil:

DIEGO OMAR TENORIO HUARANCCA

Quien presentó la tesis denominada:

Propuesta de modelo de tráfico vehicular, mediante redes neuronales artificiales, para reducir la congestión vehicular en el jirón Carlos F. Vivanco, Ayacucho, 2024

Los señores miembros del jurado luego de expuesta la tesis y absueltas las preguntas, deliberaron y declararon:

Aprobado con dieciocho (18)

Siendo las **11:30 a.m.** del día **17 de junio del 2025**, culmina el acto de sustentación de tesis, y en conformidad lo actuado los miembros del jurado firmamos al pie del presente.

Mg. Ing. José Ernesto ESTRADA CÁRDENAS
Presidente

MSc. Ing. Moisés Nico BARBARAN
ORIUNDO
Miembro

MSc. Ing. Rocky Giban AYALA BIZARRO
Miembro

Dr. Ing. Hemerson LIZARBE ALARCON
Miembro - Asesor

MSc. Ing. Saul Walter RETAMOZO
FERNÁNDEZ
Secretario docente de la FIMGC



UNSCH

FACULTAD DE
INGENIERÍA
DE MINAS, GEOLOGÍA Y CIVIL



"Año de la recuperación y consolidación de la economía peruana "

CONSTANCIA DE ORIGINALIDAD DE TRABAJO DE INVESTIGACIÓN

CONSTANCIA N° 010-2025-FIMGC/ASIH

El que suscribe; responsable verificador de originalidad de trabajos de tesis de pregrado con el software Turnitin, de la Escuelas Profesional de **Ingeniería Civil** de la **Facultad de Ingeniería de Minas, Geología y Civil**; en cumplimiento a la **Resolución de Consejo Universitario N° 039-2021-UNSCH-CU**, Reglamento de Originalidad de Trabajos de Investigación de la Universidad Nacional San Cristóbal de Huamanga y **Resolución Decanal N° 697-2024-FIMGC-UNSCH-D**, dejo constancia de originalidad de trabajo de investigación, que el/la Sr./Srta.

Apellidos y Nombres : Diego Omar Tenorio Huarancca
Escuela Profesional : INGENIERÍA CIVIL
Título de la Tesis : Propuesta de modelo de tráfico vehicular, mediante redes neuronales artificiales, para reducir la congestión vehicular en el Jirón Carlos F. Vivanco, Ayacucho, 2024
Evaluación de la Originalidad : 7 % Índice de Similitud
Identificador de la entrega : 2711596579

Por tanto, según los Artículos 12, 13 y 17 del Reglamento de Originalidad de Trabajos de Investigación, es **PROCEDENTE** otorgar la **Constancia de Originalidad** para los fines que crea conveniente.

En señal de conformidad y verificación se firma la presente constancia

Ayacucho, 7 de Julio de 2025



UNIVERSIDAD NACIONAL DE
SAN CRISTÓBAL DE HUAMANGA
Facultad de Ingeniería de Minas, Geología y Civil

Mg. Ing. Alex Sander IRCAÑAUPA HUAMANI
Verificador de Originalidad de Trabajos de Tesis de Pregrado
Escuela de Formación Profesional de Ingeniería Civil

Propuesta de modelo de tráfico vehicular, mediante redes neuronales artificiales, para reducir la congestión vehicular en el Jirón Carlos F. Vivanco, Ayacucho, 2024

por Diego Omar Tenorio Huarancca

Fecha de entrega: 07-jul-2025 04:27p. m. (UTC-0500)

Identificador de la entrega: 2711596579

Nombre del archivo: Tesis_Diego_Tenorio.pdf (8.87M)

Total de palabras: 47089

Total de caracteres: 270892

Propuesta de modelo de tráfico vehicular, mediante redes neuronales artificiales, para reducir la congestión vehicular en el Jirón Carlos F. Vivanco, Ayacucho, 2024

INFORME DE ORIGINALIDAD

7 %	6 %	1 %	2 %
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	repositorio.uni.edu.pe	2 %
	Fuente de Internet	
2	Submitted to Universidad Nacional de San Cristóbal de Huamanga	1 %
	Trabajo del estudiante	
3	hdl.handle.net	1 %
	Fuente de Internet	
4	tesis.pucp.edu.pe	<1 %
	Fuente de Internet	
5	repositorioacademico.upc.edu.pe	<1 %
	Fuente de Internet	
6	Submitted to Universidad Politécnica de Madrid	<1 %
	Trabajo del estudiante	
7	Submitted to Pontificia Universidad Javeriana Cali	<1 %
	Trabajo del estudiante	
8	www.academia.edu	<1 %
	Fuente de Internet	
9	repositorio.upeu.edu.pe	<1 %
	Fuente de Internet	
10	Submitted to Instituto Nacional de Administración Pública (	<1 %
	Trabajo del estudiante	

11	Submitted to Universidad Andina del Cusco Trabajo del estudiante	<1 %
12	Submitted to Universidad Internacional de la Rioja Trabajo del estudiante	<1 %
13	"Consideraciones para la estimación de demoras en intersecciones semaforizadas", Pontificia Universidad Catolica de Chile, 2012 Publicación	<1 %
14	sedici.unlp.edu.ar Fuente de Internet	<1 %
15	edoc.pub Fuente de Internet	<1 %
16	asociacionvenezolanadesociologia.org Fuente de Internet	<1 %
17	repositorio.uancv.edu.pe Fuente de Internet	<1 %
18	repositorio.uss.edu.pe Fuente de Internet	<1 %
19	Submitted to Instituto Superior de Artes, Ciencias y Comunicación IACC Trabajo del estudiante	<1 %
20	Submitted to Universitat Politècnica de València Trabajo del estudiante	<1 %
21	riunet.upv.es Fuente de Internet	<1 %
22	América Bueno Gómez. "Investigación y desarrollo de metodología avanzada de segmentación de la médula espinal cervical a partir de imágenes RM para la ayuda al diagnóstico y seguimiento de pacientes de	<1 %

Esclerosis Múltiple", Universitat Politecnica de Valencia, 2024

Publicación

23

oa.upm.es
Fuente de Internet

<1 %

24

www.centrogeo.org.mx
Fuente de Internet

<1 %

Excluir citas

Activo

Excluir coincidencias

< 30 words

Excluir bibliografía

Activo