

**UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL
DE HUAMANGA**

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

ESCUELA PROFESIONAL DE INGENIERÍA CIVIL



TESIS:

**"Propuesta de mejora de la seguridad vial en las vías
principales de la ciudad de Ayacucho a través de la
implementación de técnicas de inteligencia artificial"**

Para optar el título profesional de:
INGENIERO CIVIL

PRESENTADO POR:
Bach. Eduardo Jesus URBINA DOMINGUEZ

ASESOR:
Mg. Ing. Edward LEÓN PALACIOS

AYACUCHO - PERÚ

2025

RESUMEN

Esta investigación tiene como propósito desarrollar técnicas de inteligencia artificial basadas en redes neuronales convolucionales (CNN) para mejorar la seguridad vial en las vías principales de la ciudad de Ayacucho. El estudio se enfoca específicamente en la detección automatizada de 14 tipos de señalizaciones verticales conforme al Manual de Dispositivos de Control del Tránsito Automotor. Metodológicamente, se adoptó un enfoque cuantitativo con alcance explicativo y diseño no experimental. Se utilizó un muestreo no probabilístico intencional seleccionando 2,250 imágenes de señalizaciones verticales de una población inicial de 3,000 fotografías capturadas en las principales vías de Ayacucho. Los instrumentos principales incluyeron: Dispositivo móvil Samsung Galaxy S-23 para captura de imágenes, herramienta LabelMe para etiquetado de datos, arquitectura YOLOv8m entrenada durante 104 épocas con técnica EarlyStopping en GPU NVIDIA A100, y frameworks especializados como Python, OpenCV y Ultralytics YOLO. Las conclusiones principales demuestran que el modelo alcanzó métricas sobresalientes con precisión de 0.997, recall de 0.997, mAP@0.5 de 0.993 y velocidades de inferencia de 55.1 ms por imagen. Se logró desarrollar exitosamente un software que integra detección automatizada con sistema de alertas por voz optimizado, validado mediante simulaciones vehiculares en cinco circuitos urbanos de Ayacucho. El sistema demostró robustez ante condiciones adversas como señalizaciones deterioradas, parcialmente ocultas y en entornos con topografía irregular, confirmando su viabilidad para aplicaciones de seguridad vial en tiempo real y contribuyendo significativamente a la prevención de accidentes mediante tecnología de inteligencia artificial adaptada al contexto local.

Palabras clave : Redes neuronales convolucionales (CNN), seguridad vial, detección automatizada, YOLO, señalizaciones verticales, inteligencia artificial.

ABSTRACT

This research aims to develop artificial intelligence techniques based on convolutional neural networks (CNN) to improve road safety on the main roads of Ayacucho city. The study specifically focuses on the automated detection of 14 types of vertical traffic signs according to the Manual of Motor Traffic Control Devices. Methodologically, a quantitative approach with explanatory scope and non-experimental design was adopted. Intentional non-probabilistic sampling was used, selecting 2,250 images of vertical signs from an initial population of 3,000 photographs captured on the main roads of Ayacucho. The main instruments included: Samsung Galaxy S-23 mobile device for image capture, LabelMe tool for data labeling, YOLOv8m architecture trained for 104 epochs with EarlyStopping technique on NVIDIA A100 GPU, and specialized frameworks such as Python, OpenCV and Ultralytics YOLO. The main conclusions demonstrate that the model achieved outstanding metrics with precision of 0.997, recall of 0.997, mAP@0.5 of 0.993 and inference speeds of 55.1 ms per image. A software that integrates automated detection with an optimized voice alert system was successfully developed, validated through vehicular simulations in five urban circuits of Ayacucho. The system demonstrated robustness under adverse conditions such as deteriorated, partially hidden signs and environments with irregular topography, confirming its viability for real-time road safety applications and contributing significantly to accident prevention through artificial intelligence technology adapted to the local context.

Keywords: Convolutional neural networks (CNN), road safety, automated detection, YOLO, vertical traffic signs, artificial intelligence.

INTRODUCCIÓN

La congestión vehicular y los accidentes de tránsito constituyen problemáticas críticas que afectan a numerosas ciudades a nivel mundial, siendo especialmente complejas en centros urbanos con características históricas como Ayacucho, donde la morfología colonial de calles estrechas y la topografía irregular generan desafíos particulares para la seguridad vial. Los accidentes de tránsito causan anualmente aproximadamente 1.19 millones de muertes a nivel global, siendo el 92 % de estas fatalidades registradas en países de ingresos bajos y medios, categoría en la que se encuentra el Perú. En el contexto nacional, durante el año 2023 se reportaron más de 87,000 accidentes de tránsito con un saldo superior a 3,100 víctimas mortales, donde el 70 % de los siniestros viales son atribuidos a causas humanas como la imprudencia del conductor, desobediencia de señales y exceso de velocidad. La ciudad de Ayacucho presenta un sistema vial caracterizado por señalizaciones verticales deterioradas, ubicaciones inadecuadas de dispositivos de control y un incumplimiento sistemático de las normativas técnicas establecidas en el Manual de Dispositivos de Control del Tránsito Automotor, situación que se agrava por el creciente parque automotor y la limitada implementación de tecnologías modernas para la gestión del tránsito.

La elección de este problema se justifica por la convergencia de múltiples factores críticos: la necesidad urgente de desarrollar soluciones tecnológicas innovadoras que complementen la infraestructura vial existente, la disponibilidad actual de técnicas avanzadas de inteligencia artificial como las redes neuronales convolucionales, y la oportunidad de crear un sistema adaptado específicamente al contexto geográfico y cultural ayacuchano. Los métodos tradicionales de control de tráfico han demostrado limitaciones significativas en contextos urbanos complejos, especialmente cuando se enfrentan a factores como la variabilidad climática, condiciones de iluminación adversas, deterioro progresivo de la señalización y patrones de comportamiento vial irregulares.

La motivación de esta investigación surge de la oportunidad de aplicar técnicas avanzadas de inteligencia artificial, específicamente redes neuronales convolucionales y arquitecturas YOLO, para crear un sistema de detección automatizada que pueda operar en tiempo real bajo condiciones adversas, contribuyendo directamente a la reducción de accidentes y al fortalecimiento de la cultura vial preventiva. Las redes neuronales convolucionales han demostrado capacidades excepcionales en tareas de visión artificial, evidencian que los algoritmos YOLO proporcionan detección de objetos en tiempo real con alta precisión. La investigación se fundamenta en la premisa de que la integración de tecnologías de aprendizaje profundo con sistemas de alertas auditivas puede compensar las deficiencias de la infraestructura vial existente y mejorar significativamente los tiempos de reacción del conductor ante señalizaciones críticas. Esta aproximación tecnológica representa una solución escalable y costo-efectiva que puede ser replicada en contextos urbanos similares, generando un impacto positivo tanto a nivel local como regional.

A mis padres y hermanos, por ser la guía incansable en cada paso de este sendero académico, por constituir una fuente inagotable de fortaleza, compañía y aliento durante cada etapa de mi formación personal y profesional. Gracias por estar siempre presentes. Esta investigación trasciende lo individual para convertirse en un triunfo colectivo que también les pertenece.

AGRADECIMIENTOS

Extiendo mi más sincero y profundo agradecimiento a los docentes de la Escuela Profesional de Ingeniería Civil de la Universidad Nacional de San Cristóbal de Huamanga. A lo largo de mi formación académica, su compromiso constante con la enseñanza, así como la generosidad con la que compartieron sus conocimientos, experiencias y valores profesionales, contribuyeron decisivamente al desarrollo de mis capacidades técnicas, éticas y humanas. Gracias a su guía, se cimentaron las bases sólidas que hoy sostienen este trabajo de investigación.

De manera especial, deseo expresar mi gratitud al M.Sc. Ing. Edward León Palacios, director de esta tesis, por su invaluable orientación durante todo el proceso investigativo. Su amplia experiencia, dedicación permanente y rigor metodológico fueron pilares esenciales para la estructuración y concreción de este estudio. Su acompañamiento no solo facilitó el logro de los objetivos propuestos, sino que también fortaleció mi pensamiento crítico y científico.

Asimismo, manifiesto mi reconocimiento a los distinguidos miembros del jurado evaluador: Dr. Ing. Hemerson Lizarbe Alarcón y M.Sc. Ing. Moises Nico Barbaran Oriundo, quienes con su exhaustiva revisión, pertinentes observaciones y aportes especializados, enriquecieron significativamente la calidad de esta investigación. Su compromiso con la excelencia académica fue determinante para elevar el nivel metodológico y técnico de esta tesis.

A mis colegas de estudio y profesionales del campo que participaron en diversos momentos de esta investigación, les agradezco sinceramente por sus contribuciones colaborativas. Sus conocimientos, ideas, y retroalimentaciones fueron clave para la validación de resultados, el intercambio de perspectivas y el fortalecimiento del enfoque aplicado. Su acompañamiento evidenció el valor del trabajo en equipo y del aprendizaje compartido.

ÍNDICE GENERAL

ÍNDICE GENERAL	VII
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	7
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 Justificación.	7
1.4.2 Importancia.	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 Seguridad vial.	14
2.3 Marco conceptual	28
2.3.1 Técnicas de inteligencia artificial	28
3 MARCO METODOLÓGICO	41
3.1 Enfoque de la investigación.	41
3.2 Alcance de la investigación	41
3.3 Diseño de la investigación	41
3.4 Población y muestra.	42
3.4.1 Población	42
3.4.2 Muestra	42
3.5 Hipótesis	42
3.5.1 Hipótesis general	42
3.5.2 Hipótesis específicas	43
3.6 Operacionalización de variables	43
3.6.1 Variables	43

3.7	Técnicas e instrumentos.	43
3.7.1	Técnicas de recolección	43
3.7.2	Instrumentos utilizados	44
3.8	Desarrollo del trabajo de tesis.	45
3.8.1	Recopilación de datos	45
3.8.2	Conjunto de datos de entrenamiento	45
3.8.3	Etiquetado en LabelMe	46
3.8.4	Entrenamiento del modelo 104 épocas-GPU A-100	53
3.8.5	Determinación y análisis de las zonas de simulación de viajes	61
3.8.6	Desarrollo y arquitectura del sistema.	66
4	RESULTADOS	72
4.1	Contrastación de hipótesis	72
4.1.1	Contrastación de hipótesis específica 1.	72
4.1.2	Contrastación de hipótesis específica 2.	83
4.1.3	Contrastación de hipótesis específica 3.	88
5	CONCLUSIONES	105
5.1	Conclusiones.	105
5.2	Recomendaciones	107
5.3	Trabajos futuros	107
	REFERENCIAS BIBLIOGRÁFICAS	109
6	ANEXOS	113
6.1	Panel fotográfico: Recolección de fotografías en campo	113
6.2	Matriz de consistencia y operacionalización	119

LISTA DE FIGURAS

1	Vista satelital y delimitación espacial de la zona de estudio	6
2	Intervenciones prioritarias para la seguridad vial	16
3	Factores de velocidad alta	19
4	Estrategias fundamentales para prevenir accidentes	19
5	Señalización vial y su rol en la seguridad	20
6	Presentación del Manual	21
7	Señalización vertical R-27 (NE)	22
8	Ubicación correcta de la señalización vertical	23
9	Ubicación longitudinal y distancias de lectura	23
10	Señales de prioridad R-1 y R-2	24
11	Señales de prohibición de maniobras y giros	25
12	Señales de prohibición de paso por clase de vehículo	25
13	Señales preventivas por características de la superficie de rodadura	26
14	Señales preventivas por características operativas de la vía	26
15	Señalización para rampas de emergencia	27
16	Modelo matemático de una neurona artificial	30
17	Arquitectura de una CNN	32
18	Aplicación de la función de activación ReLU	34
19	Aplicación de un Max Pooling de 2x2	35
20	Ejemplo de las capas de agrupamiento	37
21	Representación de la arquitectura Yolo V.8	39
22	Representación de la arquitectura Faster-RCNN	39
23	Condiciones soleadas (R-27A)	45
24	Condiciones soleadas (P-49)	45
25	Condiciones nocturnas (R-19)	45
26	Condiciones nocturnas (P-48)	45
27	Conjunto de datos de entrenamiento en formato jpg	46
28	Etiquetado-NE-C.Soleada	48
29	Etiquetado-NE-C.Nocturna	48
30	Etiquetado-SP-C.Soleada	48
31	Etiquetado-SP-C.Nocturna	48
32	Etiquetado-P-C.Soleada	48
33	Etiquetado-P-C.Nocturna	48
34	Etiquetado-NC-C.Soleada	49
35	Etiquetado-NC-C.Nocturna	49
36	Etiquetado-PP-C.Soleada	49
37	Etiquetado-PP-C.Nocturna	49
38	Etiquetado-NCL-C.Soleada	49
39	Etiquetado-NCL-C.Nocturna	49
40	Etiquetado-VM_20-C.Soleada	50

41	Etiquetado-VM_20-C.Nocturna	50
42	Etiquetado-PA-C.Soleada	50
43	Etiquetado-PA-C.Nocturna	50
44	Etiquetado-Control de velocidad (CV)-Entorno soleado	50
45	Etiquetado-ZP-C.Soleada	51
46	Etiquetado-ZP-C.Nocturna	51
47	Etiquetado-Velocidad máxima (VM_30)-Entorno nocturno	51
48	Etiquetado-RV-C.Soleada	51
49	Etiquetado-RV-C.Nocturna	51
50	Etiquetado-Solo Buses (SB)-Entorno soleado	52
51	Etiquetado-Vehículo Restringido (VR)-Entorno soleado	52
52	Gráfico de barras-104 épocas	53
53	Gráfico bounding box distribution plot	54
54	Gráfico bounding box centers	55
55	Gráfico de dispersión 2D tipo heatmap	55
56	Gráfico scatter plot matrix	56
57	Gráfico:F1-Confidence Curve-104 épocas	56
58	Gráfico:Precisión-Confidence Curve-104 épocas	57
59	Gráfico:Recall-Confidence Curve-104 épocas	58
60	Gráfico:Precisión-Recall Curve-104 épocas	58
61	Gráfico:Precisión-Recall Curve-104 épocas	59
62	Circuito integral viaje 01	62
63	Circuito intregal viaje 02	63
64	Circuito integral viaje 03	64
65	Circuito integral viaje 04	65
66	Circuito integral viaje 05	65
67	Intefaz gráfica al iniciar el software	66
68	Selección del nivel de confianza-consola del sistema	67
69	Velocidad 1.0x-Normal balanceada	68
70	Velocidad 20.0x-Máxima velocidad	68
71	Sistema de alerta de voz optimizado por clases	69
72	Video procesado + consola de detecciones persistentes+consola del sistema: . .	71
73	Señal de prioridad (R-1)-PARE-clase PA	73
74	Señal de prohibición (R-19)-Prohibido circulación de vehículos de carga-clase NC)	73
75	Señal prohibición (R-17)-Prohibido circulación vehículos automotores-clase VR)	74
76	Señal vía segregada para buses (R-55A,R-55B,-clase SB))	74
77	Señal prohibido estacionar zona de remolque (R-27A)-clase NE)	74
78	Señal prohibido el uso de la bocina (R-29)-clase NCL	75
79	Señal paradero prohibido (R-44)-clase PP	75
80	Señal velocidad máxima permitida (R-20)- VM_20	76
81	Señal velocidad máxima permitida (R-30)- VM_30	76

82	Señal proximidad reductor de velocidad tipo resalto (P-33A)-Clase RV	77
83	Señal zona de presencia de peatones (P-48)	77
84	Señal zona escolar (P-49)	78
85	Señal de control de velocidad en autopista (I-3)-Clase CV	78
86	Señal informativa sobre tarifas en zona de parqueo	79
87	Señal informativa: I-23 Paradero de transporte público-Clase P	79
88	Detección de señalizaciones pandeadas	80
89	Detección de señalizaciones parcialmente ocluidas	80
90	Detección de señalizaciones ocluidas por arbustos	81
91	Detección de señalizaciones, visiblemente desgastadas	81
92	Detección de señalizaciones, visiblemente desgastadas y ocluidas	82
93	Detección múltiple de señalizaciones	82
94	Gráfico bounding box distribution plot	85
95	Gráfico bounding box centers	85
96	Gráfico de dispersión 2D tipo heatmap	85
97	Gráfico scatter plot matrix	86
98	Gráfico: F1-Confidence Curve - 104 épocas	86
99	Gráfico: Precisión-Confidence Curve - 104 épocas	86
100	Gráfico: Recall-Confidence Curve - 104 épocas	87
101	Gráfico: Precisión-Recall Curve - 104 épocas	87
102	Panel de métricas de entrenamiento y validación - 104 épocas	87
103	Metodología de captura de viajes	88
104	Simulación de viajes en vehículos autonomos	89
105	Circuito integral viaje 01	90
106	Detección-Clase NE-0.60	90
107	Detección-Clase NE-0.85	90
108	Detección-Clase SP-0.69	91
109	Detección-Clase NC-0.80	91
110	Detección-Clase VM_30-0.90	91
111	Detección-Clase RV-0.81	92
112	Detección-Clase SP-0.81	92
113	Detección-Clase NE-0.81	92
114	Detección-Clase SP-0.87	93
115	Detección-Clase NC-0.60	93
116	Detección-Clase NE-0.90	93
117	Circuito intregal viaje 02	94
118	Detección-Clase SP-0.68	94
119	Detección-Clase NE-0.83	95
120	Detección-Clase NC-0.81	95
121	Detección-Clase NCL-0.91	95
122	Detección-Clase VM_20-0.90	96

123	Detección-Clase P-0.59	96
124	Detección-Clase ZP-0.63	96
125	Detección-Clase VR-0.88	97
126	Detección-Clase NE-0.82	97
127	Detección-Clase NE-0.82-Estable	97
128	Circuito integral viaje 03	98
129	Detección-Clase RV-0.65	98
130	Detección-Clase NE-0.91	99
131	Detección-Clase NE-0.92	99
132	Detección-Clase NE-0.83	99
133	Detección-Clase SP-0.75	100
134	Detección-Clase SP-0.88	100
135	Detección-Clase P-0.90	100
136	Circuito integral viaje 04	101
137	Detección nocturna-Clase RV-0.87	101
138	Detección nocturna-Clase NE-0.86	102
139	Detección nocturna-Clase NE-0.85	102
140	Circuito integral viaje 05	103
141	Detección nocturna-Clase NE-0.59	103
142	Detección nocturna-Clase NE-0.82	104
143	Detección nocturna-Clase NC-0.56	104
144	Detección nocturna-Clase VM_30-0.83	104
145	Verificación del estado situacional de la señalización (R-27A)	113
146	Señal de prohibición (R-27A) Ubicada en el Jr. Tres Máscaras	113
147	Señal preventiva (P-33A)-Ubicada inadecuadamente	114
148	Señal preventiva (P-33A), obstaculizando el paso peatonal	114
149	Señal de restricción (R-30)	115
150	Señal (R-27A)-Notoriamente desgastada	115
151	Incumplimiento de la señal (R-27A)	116
152	Incumplimiento de la señal Prohibido Estacionar	116
153	Señal (R-27A) presenta inclinación lateral considerable	117
154	Señal (R-27A) sin parante de soporte estructural independiente	117
155	Señal (R-27A) sujeta directamente al poste de alumbrado público	118
156	Ausencia de señalización vertical	118
157	Instalación de las cámaras de investigación	119

LISTA DE CUADROS

1	Proceso de convoluciones a una imagen de 48x48 píxeles	36
2	Definición de categorías (clases)	47
3	Distribución de instancias por categoría de señalizaciones	54
4	Resultados mAP50 y mAP50-95, 104 épocas	60
5	Tiempos de Procesamiento-104 épocas-YOLOv8S, GPU A100 de 40 GB.	60
6	Sistema de alerta de voz optimizado por clases	69
7	Señalizaciones verticales detectadas por el modelo	72
8	Resultados mAP50 y mAP50-95, 104 épocas	84
9	Tiempos de Procesamiento - 104 épocas - YOLOv8, GPU A100 de 40 GB	84

GLOSARIO

Arquitectura YOLOv8	Modelo de detección de objetos de octava generación que utiliza redes neuronales convolucionales para identificación en tiempo real con alta precisión.
Bounding Box	Rectángulo delimitador que localiza y enmarca un objeto detectado en una imagen durante el procesamiento de visión artificial.
CNN	Red Neuronal Convolucional, arquitectura de aprendizaje profundo especializada en procesamiento de imágenes y reconocimiento de patrones visuales.
Confianza	Valor numérico entre 0 y 1 que indica el grado de certeza del modelo sobre la presencia y clasificación correcta de un objeto detectado.
Early Stopping	Técnica que detiene automáticamente el entrenamiento cuando deja de mejorar el rendimiento, evitando el sobreajuste.
Época	Una iteración completa a través de todo el conjunto de datos de entrenamiento durante el proceso de aprendizaje del modelo.
GPU A100	Unidad de procesamiento gráfico de alta gama diseñada para acelerar el entrenamiento de modelos de inteligencia artificial.
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@0.5	Mean Average Precision con umbral IoU de 0.5, métrica estándar para evaluar precisión en modelos de detección de objetos.
Manual MDCTA	Manual de Dispositivos de Control del Tránsito Automotor, documento normativo que establece estándares para señalización vial en Perú.
Pooling	Operación que reduce la dimensionalidad espacial de una representación, conservando la información más relevante.
Precisión	Métrica que mide la proporción de predicciones positivas correctas respecto al total de predicciones positivas realizadas por el modelo.
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.
Seguridad Vial	Conjunto de medidas y estrategias diseñadas para prevenir accidentes de tránsito y proteger a todos los usuarios de las vías públicas.
Señalización Vertical	Dispositivos de control del tránsito instalados verticalmente para reglamentar, prevenir e informar a conductores y peatones.
Sistema de Alertas	Mecanismo automatizado que emite advertencias sonoras contextualizadas basadas en la detección de señales de tránsito.
Sobreajuste	Fenómeno donde un modelo se adapta excesivamente a los datos de entrenamiento, perdiendo capacidad de generalización.
Tiempo de Inferencia	Duración requerida por el modelo para procesar una imagen y generar predicciones, medido típicamente en milisegundos.
YOLO	You Only Look Once, algoritmo de detección de objetos en tiempo real que analiza la imagen completa en una sola pasada.

ACRÓNIMOS

AI	Artificial Intelligence (Inteligencia Artificial), campo de la informática enfocado en crear sistemas que simulan capacidades cognitivas humanas.
CNN	Convolutional Neural Network (Red Neuronal Convolucional), arquitectura de aprendizaje profundo especializada en procesamiento de imágenes y visión artificial.
CV	Computer Vision (Visión por Computadora), disciplina que permite a las máquinas interpretar y procesar información visual del mundo real.
DL	Deep Learning (Aprendizaje Profundo), subset del machine learning que utiliza redes neuronales multicapa para análisis de datos complejos.
EDA	Exploratory Data Analysis (Análisis Exploratorio de Datos), proceso de investigación inicial de conjuntos de datos para descubrir patrones y características.
FPS	Frames Per Second (Fotogramas Por Segundo), medida de velocidad de procesamiento en sistemas de detección en tiempo real.
GPU	Graphics Processing Unit (Unidad de Procesamiento Gráfico), hardware especializado para acelerar el entrenamiento de modelos de inteligencia artificial.
IoU	Intersection over Union (Intersección sobre Unión), métrica fundamental para evaluar precisión de detección en modelos de visión artificial.
JSON	JavaScript Object Notation, formato de intercambio de datos utilizado para almacenar anotaciones de imágenes etiquetadas.
mAP	mean Average Precision (Precisión Media Promedio), métrica estándar para evaluar rendimiento de algoritmos de detección de objetos.
MDCTA	Manual de Dispositivos de Control del Tránsito Automotor, documento normativo oficial para señalización vial en Perú.
ML	Machine Learning (Aprendizaje Automático), rama de la IA que permite a los sistemas aprender y mejorar automáticamente a partir de datos.
NMS	Non-Maximum Suppression (Supresión de No Máximos), algoritmo para eliminar detecciones redundantes en modelos YOLO.
OpenCV	Open Source Computer Vision Library, biblioteca de código abierto para procesamiento de imágenes y visión artificial.
ReLU	Rectified Linear Unit (Unidad Linear Rectificada), función de activación predominante en redes neuronales convolucionales modernas.
RGB	Red, Green, Blue (Rojo, Verde, Azul), modelo de color utilizado en procesamiento digital de imágenes para señalizaciones.
SGD	Stochastic Gradient Descent (Descenso de Gradiente Estocástico), algoritmo de optimización utilizado en entrenamiento de CNN.
TTS	Text-to-Speech (Texto a Voz), tecnología utilizada para generar alertas auditivas automatizadas en el sistema de seguridad vial.
YOLO	You Only Look Once (Solo Miras Una Vez), arquitectura de detección de objetos en tiempo real utilizada para identificar señalizaciones verticales.

LISTA DE SÍMBOLOS

α	Parámetro de tasa de aprendizaje en algoritmos de optimización para entrenamiento de redes neuronales convolucionales.
β	Factor de momento en algoritmos de optimización SGD utilizados durante el entrenamiento del modelo YOLOv8.
γ	Parámetro de decaimiento de la tasa de aprendizaje aplicado durante las épocas de entrenamiento.
δ	Umbral de confianza mínimo para considerar válida una detección de señalización vertical.
ϵ	Valor de tolerancia utilizado en la técnica Early Stopping para determinar la convergencia del modelo.
η	Tasa de aprendizaje (learning rate) específica utilizada en el entrenamiento del modelo CNN.
θ	Conjunto de parámetros y pesos de la red neuronal convolucional YOLOv8m.
λ	Parámetro de regularización L2 aplicado para prevenir el sobreajuste durante el entrenamiento.
μ	Media de la distribución de datos de entrada normalizada antes del procesamiento por la CNN.
σ	Desviación estándar de la normalización aplicada al conjunto de datos de señalizaciones verticales.
τ	Tiempo de procesamiento por imagen medido en milisegundos durante la fase de inferencia.
ϕ	Función de activación ReLU aplicada en las capas convolucionales: $\phi(x) = \max(0, x)$.
ψ	Función de pérdida combinada utilizada en YOLOv8 que incluye clasificación, localización y confianza.
ω	Pesos sinápticos específicos de las conexiones entre neuronas en la arquitectura CNN.
C	Valor de confianza de detección para cada clase de señalización vertical identificada.
$F1$	Puntuación F1-Score calculada como: $F1 = 2 \times \frac{Precisin \times Recall}{Precisin + Recall}$.
IoU	Intersection over Union, métrica de evaluación: $IoU = \frac{rea\ de\ Intersección}{rea\ de\ Unión}$.
mAP	Mean Average Precision calculada a diferentes umbrales IoU para evaluación del modelo.
N	Número total de imágenes en el conjunto de datos de entrenamiento (2,250 imágenes).
P	Precisión del modelo de detección, relación entre verdaderos positivos y total de predicciones positivas.
R	Recall o sensibilidad del modelo, relación entre verdaderos positivos y total de positivos reales.
t_{inf}	Tiempo de inferencia promedio por imagen expresado en milisegundos (55.1 ms).
X_{input}	Tensor de entrada de dimensiones específicas procesado por las capas convolucionales CNN.
Y_{pred}	Tensor de salida con las predicciones de bounding boxes y clasificaciones de señales verticales.

TESIS

1. PLANTEAMIENTO DEL PROBLEMA

1.1. Descripción del problema

A nivel global, la seguridad vial continúa siendo uno de los principales desafíos para la salud pública y la seguridad ciudadana. Los accidentes de tránsito causan anualmente aproximadamente 1.19 millones de muertes, además de entre 20 y 50 millones de lesiones, muchas de ellas con consecuencias discapacitantes de largo plazo. Estas cifras son especialmente alarmantes en los países de ingresos bajos y medios, donde ocurre el 92 % de las muertes, a pesar de contar con solo el 60 % del parque automotor. Entre las causas principales se encuentran el exceso de velocidad, la conducción bajo efectos de sustancias, la distracción al volante y, especialmente, la falta de respuesta adecuada a la señalización vial. Esta situación pone en evidencia la necesidad de abordar el problema desde una perspectiva tecnológica e innovadora, en un escenario donde la interacción entre el ser humano y los sistemas de advertencia visual sigue siendo ineficiente ante condiciones cambiantes o de riesgo.(Organización mundial de la salud (2023))

En el Perú, la problemática del tránsito adquiere características aún más críticas debido a factores estructurales y humanos. En el año 2023, se reportaron más de 87,000 accidentes de tránsito con un saldo de más de 3,100 víctimas mortales, ubicando al país como uno de los más afectados en la región andina (Highways (2024)). El 70 % de los siniestros viales son atribuidos a causas humanas, como imprudencia del conductor, desobediencia de señales y exceso de velocidad. Si bien la infraestructura ha experimentado cierto avance, el sistema vial peruano todavía presenta deficiencias significativas, especialmente en cuanto a señalización vertical clara, visible y técnicamente adecuada. Además, no se cuenta con un sistema integrado de asistencia en tiempo real que refuerce la percepción del entorno vial. Esta situación expone a conductores y peatones a un riesgo constante, y revela la ausencia de políticas tecnológicas efectivas que promuevan el uso de herramientas basadas en inteligencia artificial para mitigar este tipo de peligros.

La región Ayacucho, debido a su topografía accidentada y la dispersión de su población en zonas rurales de difícil acceso, presenta un panorama crítico en materia de seguridad vial. Las vías interprovinciales e interregionales presentan características geográficas de alto riesgo, como curvas cerradas, pendientes pronunciadas, escasa iluminación y señalización deteriorada o inexistente. Además, los vehículos que transitan por estas rutas muchas veces no están equipados con tecnologías de asistencia al conductor. Este escenario pone en evidencia la urgencia de desarrollar estrategias innovadoras para mejorar la interpretación y respuesta ante señales de tránsito, especialmente aquellas que tienen un rol preventivo o regulador. La falta de recursos tecnológicos para reconocer visualmente señales en tiempo real limita severamente la capacidad de respuesta de los conductores, agravando el riesgo de siniestros en entornos rurales como los de Ayacucho.

Como señala la (Municipalidad Provincial de Huamanga (2020) p-392): “La ciudad de Ayacucho no cuenta con una señalización adecuada. Solo existen algunas señales. La ciudad necesita con urgencia la implementación de un Plan de Señalización.”

A razón de ello, los principales afectados por la deficiente seguridad vial en la ciudad de Ayacucho son los conductores, peatones y pasajeros que transitan diariamente por las vías urbanas. Estos actores viales enfrentan un alto riesgo de sufrir accidentes debido a la baja visibilidad, el mal estado de las señalizaciones y la falta de advertencias oportunas. En particular, los motociclistas y ciclistas, que representan una proporción creciente del parque vehicular en la ciudad, están especialmente expuestos a estos riesgos. Asimismo, niños, adultos mayores y personas con discapacidad enfrentan mayores niveles de vulnerabilidad al desplazarse en un entorno urbano con señalización deficiente o poco clara.

Las causas principales que originan el problema se encuentra en el deterioro avanzado de las señalizaciones verticales, la ausencia de mantenimiento periódico, y el incumplimiento de las normativas técnicas de instalación, como lo evidenció tu investigación en las simulaciones urbanas. Además, la topografía irregular de Ayacucho, con calles estrechas y pendientes pronunciadas, complica aún más la visibilidad y lectura de las señales. A ello se suma la creciente congestión vehicular y la limitada integración de tecnologías modernas para la gestión del tránsito, lo cual dificulta una respuesta preventiva y oportuna ante situaciones de riesgo.

Si el problema no es abordado de manera efectiva, es previsible un incremento en los accidentes de tránsito, con consecuencias graves como lesiones, muertes y daños materiales. Además, el tiempo de reacción de los conductores ante señales no visibles o confusas se ve comprometido, generando mayor probabilidad de maniobras peligrosas. A largo plazo, la falta de intervención puede deteriorar la confianza ciudadana en los sistemas de control vial y agravar el caos vehicular en zonas críticas del centro histórico, afectando incluso la movilidad urbana sostenible.

El problema se manifiesta principalmente en zonas urbanas con alto tránsito, especialmente en calles del centro histórico de Ayacucho que conservan morfología colonial, donde las vías son estrechas, las esquinas limitan el campo visual, y las pendientes reducen la visibilidad anticipada de las señales. Asimismo, las condiciones climáticas variables, la iluminación insuficiente en horas nocturnas y la falta de sistemas tecnológicos de apoyo, como alertas por voz o detección automatizada, exacerban los riesgos viales. Las pruebas en tu estudio confirman que estas condiciones afectan directamente la efectividad de los modelos de detección y alertas.

Con respecto al impacto socioeconómico es significativo, ya que los accidentes de tránsito generan costos directos en atención médica, reparación vehicular y pérdida de productividad laboral, así como costos indirectos asociados al trauma psicológico, discapacidad o pérdida de vidas humanas.

1.2. Delimitación del problema

1.2.1. Espacial (geográfica)

El área de investigación se encuentra localizada en las principales vías de la ciudad de Ayacucho, que incluyen: Calle Nazareno, Jr. Carlos F. Vivanco, Jr. Libertad, Av. Mariscal Cáceres, Jr. Sol, Jr. Garcilaso de la Vega, Jr. Callao, Jr. Lima, Jr. San Martín, Jr. Tres Máscaras, Jr. 02 de Mayo, Jr. Cusco, Jr. Arequipa, Jr. Bellido, Jr. Grau, Av. Independencia, Av. 26 de Enero, Jr. Garcilazo de la Vega, Jr. Mario Ramos, Jr. Huanta, Av. Los Pinos, Jr. Asamblea, Jr. Sucre, Jr. Francisco Pizarro.

La ejecución de la investigación se realizó en:



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

1.2.2. Temporal

Esta investigación se enmarca temporalmente entre septiembre de 2024 y julio de 2025. Durante este periodo se llevaron a cabo la recolección de datos, la grabación de viajes de simulación, el entrenamiento del modelo y el desarrollo del software, seguidos por el procesamiento analítico y la posterior interpretación de los hallazgos obtenidos a partir del estudio.

1.2.3. Temática y unidad de análisis

- **Temática:** La presente investigación se enmarca en el campo de la seguridad vial y la ingeniería del transporte, con énfasis en el uso de tecnologías emergentes aplicadas al tránsito urbano. En específico, se aborda la implementación de técnicas de inteligencia artificial como redes neuronales convolucionales (CNN) orientadas a la detección automatizada de señalizaciones verticales y su integración con sistemas de alerta para la prevención de accidentes, contribuyendo así al mejoramiento de la seguridad en las principales vías de la ciudad de Ayacucho.
- **Unidad de análisis :** La unidad de análisis de esta investigación corresponde a las señalizaciones verticales presentes en las vías principales de Ayacucho, así como su interacción con los usuarios viales. Este análisis se basa en imágenes capturadas durante simulaciones de tránsito urbano, las cuales son procesadas mediante algoritmos de visión por computadora para identificar, clasificar y emitir alertas sonoras. Los datos extraídos permiten evaluar el nivel de reconocimiento y respuesta del sistema ante distintos tipos de señales, constituyendo así la base para la propuesta de mejora en la gestión vial.

1.3. Formulación del problema

1.3.1. Problema general

¿De qué manera las técnicas de inteligencia artificial , basadas en redes neuronales convolucionales (CNN), mejoran la seguridad vial en las vías principales de la ciudad de Ayacucho?

1.3.2. Problemas específicos

1. ¿Cómo la arquitectura del modelo,basado en redes neuronales convolucionales (CNN) permite la detección , clasificación de 14 señalizaciones verticales basado en el Manual de dispositivos de control del tránsito automotor?
2. ¿En qué medida el entrenamiento del modelo basado en redes neuronales convolucionales (CNN) logra una mayor precisión de clase,recall y velocidades de inferencia ultrarrápidos, evitando el sobreajuste?
3. ¿De qué manera la implementación del modelo , basado en redes neuronales convolucionales (CNN) permite el desarrollo de un software para la detección automatizada de señalizaciones verticales, integrando un sistema de alertas por voz optimizado que garantice una reproducción inmediata y sincrónica, fundamental para la emisión oportuna de advertencias en materia de seguridad vial?

1.4. Justificación e importancia

1.4.1. Justificación

El crecimiento del parque automotor y el aumento del flujo vehicular en las principales vías de la ciudad de Ayacucho han generado nuevos desafíos en materia de seguridad vial.

La inadecuada identificación de señalizaciones verticales por parte de los conductores, así como la falta de sistemas preventivos de advertencia, contribuyen significativamente a la ocurrencia de accidentes de tránsito. Ante esta problemática, se hace necesario el desarrollo de soluciones tecnológicas que apoyen la detección oportuna de señales de tránsito, mejoren la atención del conductor y, en consecuencia, reduzcan los riesgos viales. En ese contexto, esta investigación propone la aplicación de técnicas de inteligencia artificial, en particular redes neuronales convolucionales (CNN), para automatizar la identificación de señales de tránsito verticales y activar un sistema de alertas por voz en tiempo real. Este enfoque ofrece una alternativa innovadora y escalable para reforzar los mecanismos de seguridad vial urbana mediante herramientas digitales adaptativas.

1.4.2. Importancia

La presente investigación aporta valor tanto a nivel tecnológico como social. Desde el ámbito técnico, representa una contribución al desarrollo de sistemas inteligentes de asistencia a la conducción, integrando visión computacional, procesamiento de imágenes y generación de alertas sincrónicas. A nivel práctico, la solución propuesta podría ser implementada como parte de sistemas de apoyo en vehículos particulares, unidades de transporte público o plataformas de monitoreo urbano, promoviendo una conducción más segura. Asimismo, al centrarse en un contexto local (Ayacucho), la investigación proporciona datos relevantes y contextualizados que pueden servir como base para políticas públicas de gestión del tránsito y prevención de accidentes.

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:** Aunque la propuesta integra técnicas avanzadas de inteligencia artificial, su aplicación práctica se desarrolla en un entorno simulado debido a restricciones presupuestales y logísticas.
- **Impacto humano y errores:** A pesar del alto grado de automatización del sistema, el proceso de etiquetado de datos y entrenamiento del modelo requiere intervención manual. Esto puede introducir errores o sesgos en los datos, especialmente si la calidad de las imágenes o la clasificación inicial no es rigurosa. Asimismo, la efectividad del modelo depende de la experiencia del equipo técnico encargado.
- **Enfoque en un contexto geográfico específico:** La investigación se centra únicamente en las vías principales de la ciudad de Ayacucho, por lo que sus resultados y propuestas pueden no ser generalizables a otras ciudades con dinámicas viales diferentes, infraestructura distinta o señalización no estandarizada.
- **Enfoque en un contexto geográfico específico:** El sistema propuesto se enfoca principalmente en la detección de señalizaciones verticales. No incluye la detección de otros elementos viales como marcas en el pavimento, señales luminosas o condiciones climáticas adversas, que también influyen en la seguridad del tránsito.

1.6. Objetivos de la investigación

1.6.1. Objetivo general

Desarrollar técnicas de inteligencia artificial, basadas en redes neuronales convolucionales (CNN) que permitan mejorar la seguridad vial en las vías principales de la ciudad de Ayacucho.

1.6.2. Objetivos específicos

1. Desarrollar la arquitectura del modelo, basado en redes neuronales convolucionales (CNN), que permita la detección, clasificación de 14 señalizaciones verticales basado en el Manual de dispositivos de control del tránsito automotor.
2. Al simular el entrenamiento del modelo, basado en redes neuronales convolucionales (CNN), se logra una mayor precisión de clase, recall y velocidades de inferencia ultrarrápidos, evitando el sobreajuste.
3. Determinar como la implementación del modelo basado en redes neuronales convolucionales (CNN) permite el desarrollo de un software para la detección automatizada de señalizaciones verticales, integrando un sistema de alertas por voz optimizado que garantice una reproducción inmediata y sincrónica, fundamental para la emisión oportuna de advertencias en materia de seguridad vial.

2. MARCO TEÓRICO

2.1. Antecedentes

2.1.1. Investigaciones internacionales

Bhuvaneshwari et al. (2025) desarrollan un sistema de asistencia al conductor que integra detección de señales de tráfico y clasificación usando aprendizaje profundo para abordar la creciente problemática de accidentes vehiculares. El sistema propuesto integra Traffic Sign Detection, Classification y Voice Alert Module utilizando You Only Look Once Version 4 (YOLO V4) para detección y una Red Neuronal Convolucional (CNN) para clasificación, logrando un reconocimiento preciso de señales. Los autores seleccionaron imágenes del conjunto de datos German Traffic Sign Recognition Benchmark (GTSRB) para entrenar el modelo CNN y el sistema YOLO. Para mejorar el aspecto de seguridad del sistema, integran un módulo de generación de alertas de voz que, cuando se detecta una señal de tráfico, genera alertas de voz o advertencias basadas en el significado de la señal reconocida. Estas alertas de voz están diseñadas para guiar y notificar al conductor sobre regulaciones de tráfico importantes o advertencias, como límites de velocidad, señales de alto y cruces peatonales, promoviendo una conducción más segura para todos los usuarios de la carretera.

Qiu et al. (2025) proponen un algoritmo de detección de señales de tráfico basado en YOLOv8s para mejorar el reconocimiento de objetos pequeños. Los autores removieron la capa de detección de objetos grandes y agregaron una capa específica para objetos pequeños. Diseñaron el módulo DBBNCSPELAN4 para mejorar la extracción de características y el módulo PTCSP que incorpora tecnología Transformer, reduciendo parámetros y costo computacional. Además, introducen la pérdida W3F_MPDIoU para mitigar el impacto de muestras de baja calidad. Los experimentos demuestran que DP-YOLO reduce los parámetros del modelo en 77.0 % comparado con YOLOv8s, mientras logra mejoras en mAP0.5 de 5.8 % en TT100K, 2.7 % en GTSDb y 1.3 % en CCTSDb, mostrando alto potencial para despliegue en el borde.

Han et al. (2024) desarrollan un método de detección de señales de tráfico multiescala para escenas complejas que aborda los desafíos de la detección en sistemas de conducción autónoma. Los autores identifican que las variaciones significativas del tamaño de las señales de tráfico causan problemas de falsos positivos y falsos negativos en los resultados de detección. El método utiliza EfficientVit para reemplazar la red backbone original y mejorar el rendimiento de percepción de características globales del modelo sin aumentar su complejidad. Además, emplean una cabeza de detección desacoplada eficiente para manejar las tareas de clasificación y regresión por separado, mejorando el rendimiento de detección en objetivos multiescala. Finalmente, introducen una función de pérdida optimizada que combina la pérdida CIoU con la pérdida NWD como pérdida de localización, mejorando la sensibilidad del modelo hacia señales de tráfico pequeñas. Los experimentos en los conjuntos de datos GTSDb y TT100K demuestran que EDN-YOLO exhibe un rendimiento sobresaliente en la detección de señales de tráfico multiescala en

escenarios complejos, con mejoras del 3.1 % en GTSDb y 9.6 % en TT100K comparado con el modelo YOLOv5s original.

Zhao et al. (2024) sintetizan un modelo robusto de detección y reconocimiento de señales de tráfico para mejorar la seguridad en la conducción autónoma. Los autores abordan los desafíos que enfrentan las tecnologías existentes en condiciones adversas como clima complejo y entornos de carretera diversos. El modelo utiliza las tecnologías Mamba y YOLO para mejorar la precisión y robustez de la detección de señales de tráfico. TSD-YOLO incorpora un módulo de doble rama YOLO-MAM que combina la extracción de características locales basada en capas convolucionales con las capacidades de dependencia a larga distancia de los Modelos de Estado Espacial (SSMs). Los experimentos realizados utilizando el conjunto de datos Tsinghua-Tencent 100K (TT-100K) y el conjunto de datos Mapillary Traffic Sign Detection (MTSD) demuestran la eficacia del modelo en varios conjuntos de datos. Las validaciones cruzadas confirman la excepcional generalización y robustez del modelo en diversos entornos, fortaleciendo tanto la detección como el reconocimiento de señales de tráfico en sistemas de conducción autónoma.

Sun et al. (2025) proponen un nuevo marco de detección de objetos para abordar las deficiencias en la detección precisa y rápida de señales de tráfico en sistemas de conducción autónoma. Los autores identifican que los enfoques existentes que incorporan módulos de atención o modifican las cabezas de detección frecuentemente resultan en altas tasas de detecciones falsas y pérdidas debido al aumento de la profundidad de muestreo. Para resolver estas deficiencias, introducen tres componentes principales: la fusión de secuencia adaptativa que coordina características diversificadas para amplificar la precisión de fusión de localización e información semántica, el módulo de mejora de características de auto-calibración que ajusta dinámicamente las características originales y fusionadas para mejorar su expresión característica, y la reconstrucción de características basada en wavelets que adopta una descomposición de características 2D y reconstrucción para extraer características dominantes mientras debilita los ruidos de alta frecuencia. Los estudios comparativos en los conjuntos de datos TT100K y CCTSDb 2021 demuestran un rendimiento superior de ERF-YOLO, logrando 84.2 % y 84 % respectivamente, con mejoras significativas sobre sus referencias de 5.5 % y 1.4 % respectivamente.

Chen et al. (2024) presentan una revisión sistemática que analiza el progreso en métodos y algoritmos de detección y reconocimiento de señales de tráfico durante la última década, examinando las fortalezas y debilidades de cada algoritmo. Los autores destacan que el desarrollo reciente del reconocimiento de señales de tráfico en carreteras resalta la necesidad de detección precisa de señales de tráfico en diversos escenarios de conducción. Se revelan las investigaciones entre algoritmos de detección antes y después del aprendizaje profundo, categorizando los métodos de reconocimiento de señales de tráfico en tres técnicas principales: métodos convencionales, basados en aprendizaje profundo e híbridos. Los algoritmos se comparan mediante regresión, segmentación y técnicas híbridas, específicamente SSD, YOLO, Faster R-CNN, Pixel Aggregation Network

y Mask R-CNN. Los resultados demuestran que los algoritmos de detección basados en híbridos superan a otros en tasas de verdaderos positivos, tasas de falsos positivos, número de imágenes detectadas, precisión y tiempo de procesamiento. Los autores concluyen que estos resultados ilustran el potencial de los métodos híbridos en la creación de sistemas TSD precisos y efectivos, allanando el camino para futuras investigaciones en este campo.

2.1.2. Investigaciones nacionales

En su investigación Arenas (2016), desarrolla un sistema de clasificación de señales de tránsito vehicular utilizando redes neuronales convolucionales en respuesta a la problemática de accidentes de tránsito reportados entre 2004-2015 (1,041,704 casos), donde el exceso de velocidad constituye uno de los principales factores. El autor propone que estas cifras y la probabilidad de tragedias pueden reducirse significativamente mejorando el monitoreo vehicular mediante ciudades más inteligentes capaces de reconocer zonas de pobreza, actos criminales y violaciones de señales de tránsito. La investigación presenta una solución basada en Deep Learning, técnica de inteligencia artificial utilizada previamente para reconocimiento óptico de caracteres, clasificación de imágenes, reconocimiento facial y de voz, y diagnóstico de enfermedades. Debido a la ausencia de una base de datos de señales de tránsito peruanas, se realizaron varios diseños basados en señales alemanas, logrando un porcentaje de aciertos del 95.29 %, similar al estado del arte (99.46 %). Con fines demostrativos, se implementó el diseño en una aplicación para iPhone que clasifica señales de tránsito utilizando la cámara del teléfono.

Sifuentes Rodriguez y Alarco Basaldua (2023) abordan la problemática de seguridad vial que enfrenta Lima, la cual afecta a peatones, conductores, ciclistas y demás usuarios de la vía. Los autores identifican que entre las causas de la inseguridad vial se encuentran la falta de educación vial, deficiente señalización y escaso mantenimiento de las pistas como veredas de Lima. La investigación propone la implementación de medidas ingenieriles de bajo costo en un punto específico denominado "punto negro", donde las medidas propuestas serán validadas mediante el modelamiento de software que estimará el mejoramiento de la seguridad vial con la aplicación de las medidas sugeridas. Los autores destacan que los beneficios de mejorar la seguridad vial incluyen la reducción de accidentes de tránsito, tasas de lesiones y mortalidad, disminución de la carga económica familiar asociada a gastos médicos y pérdida de productividad por muertes o discapacidad de los lesionados. La investigación busca mejorar la seguridad vial mediante indicadores como flujo vehicular, semaforización y nivel de servicio, beneficiando a la población limeña que transita por esa zona para que perciba una vía más segura.

En su estudio Quispe Condor (2024) desarrolla una red neuronal para predecir accidentes de tránsito basándose en factores geométricos de la vía en el tramo Tarma-La Merced de la Carretera Central. La investigación busca detectar zonas peligrosas con alto riesgo de accidentes considerando características geométricas específicas del trazado, incluyendo tipo de curva (tangente o curva con radios pequeños 20m-50m, medianos 50m-100m, grandes 100m-200m o muy grandes >200m), ángulo de deflexión (bajo 0°-45°, mediano

45°-90° o alto >90°), pendiente longitudinal (baja 0°-3°, media 3°-7° o alta 7°-12°) y condiciones de visibilidad (mala, regular o buena). El autor implementó diversas arquitecturas de redes neuronales iterando desde 2 a 24 nodos de entrada y 4 a 22 nodos ocultos, seleccionando la estructura con menor error predictivo. Los resultados revelan que las zonas de alto riesgo corresponden a sectores con curvas de radios pequeños y medianos, ángulos de deflexión medios y altos, pero sorprendentemente incluyen tramos rectos con longitudes medianas y cortas clasificados como zonas de riesgo medio y alto. El modelo concluye que en estas zonas los conductores realizan maniobras de adelantamiento que frecuentemente resultan en maniobras temerarias y accidentes.

Távora Idrogo (2019) implementa un modelo basado en aprendizaje profundo de redes neuronales convolucionales para el reconocimiento automático de señales de tránsito vehicular utilizando técnicas de procesamiento de imágenes y fundamentos de inteligencia artificial. El proyecto se centra en señales de tránsito vehicular de Alemania y Perú, identificando 43 y 7 categorías respectivamente. La investigación inicia con la adquisición de imágenes, procediendo a realizar el procesamiento de estas con la finalidad de aumentar el conjunto de datos y ejecutar el aprendizaje profundo a través de diversos diseños de modelos de redes neuronales convolucionales. Como resultado final, el autor obtuvo un modelo con buenos indicadores y resultados en el reconocimiento de señales de tránsito vehicular. La investigación busca contribuir a los esfuerzos de la industria automotriz en el campo de sistemas avanzados de asistencia al conductor, formando parte de diversos mecanismos que buscan dar soluciones a la inseguridad vial.

Ramos Zúñiga (2021) propone herramientas que permiten automatizar el proceso del inventario vial, desarrollando un algoritmo para detectar y reconocer señales de tránsito peruanas del tipo preventivas en la Av. Eduardo Habich ubicada en Lima Metropolitana, distrito de San Martín de Porres. El tramo seleccionado se encuentra entre la Av. Túpac Amaru y vía Panamericana Norte con una longitud aproximada de 1km. La investigación se basa en algoritmos de procesamiento de imágenes, proponiéndose una metodología dividida en dos partes: recolección de datos en campo para la base de datos y procesamiento de información en gabinete. La autora recolectó 2026 imágenes de señales preventivas de vías de Lima capturadas con cámaras de distintas resoluciones. La etapa de detección utiliza filtros de color y forma, realizando una comparación entre filtros HSV y RGB normalizado que permitió distinguir cuál tenía mejor performance. La etapa de reconocimiento emplea herramientas de clasificación supervisada con el algoritmo de máquinas de vectores de soporte. Finalmente, la investigación logró obtener un algoritmo que permite la detección de señales de tránsito con un porcentaje de reconocimiento del 62.5% y una base de datos sólida que puede ser retroalimentada para futuras investigaciones en la materia de estudio.

Matos Levano (2020) desarrolla una investigación con el objetivo de implementar un sistema de señalización vial para la prevención de accidentes de tránsito en el área de influencia comprendida entre el tramo Jirón de la Salud hasta la Avenida Héroes del

Cenepa. El autor utiliza una metodología de diseño no experimental de corte transversal, recopilando información en un solo momento mediante técnicas aplicadas en la realidad. La investigación es explicativa causal ya que existe relación de causa y efecto entre las variables, y cuantitativa mediante la recolección de datos por observación directa y procesamiento para análisis del estudio de tráfico. Los resultados del análisis de datos obtenidos en campo revelan un exceso de velocidad superior al permitido en la vía y la existencia de riesgo de accidentes de tránsito debido a la gran demanda de presencia peatonal en el área de influencia. El autor concluye que la implementación de un sistema de señalización vial influye de manera positiva para la prevención de accidentes de tránsito en el área de influencia estudiada.

2.2. Bases teóricas

2.2.1. Seguridad vial

2.2.1.1 Definición de seguridad vial

La seguridad vial se refiere a las medidas adoptadas para reducir el riesgo de lesiones y muertes causadas por el tránsito. A través de la coordinación y colaboración intersectorial, los países de la región de las Américas pueden mejorar la legislación sobre seguridad vial, creando un entorno más seguro, accesible, y sostenible para los sistemas de transporte y para todos los usuarios ((Organización Panamericana de la Salud (2024))). Este enfoque integral requiere la participación de múltiples sectores, tales como los del transporte, la policía, la salud y la educación, así como del sector privado y de organizaciones de la sociedad civil. traumatismos causados por el tránsito Exige medidas que aborden la seguridad de las carreteras, los vehículos y todos los usuarios de la carretera, incluyendo el diseño de infraestructuras más seguras e incorporando características de seguridad vial en la planificación del uso del terreno y del transporte, mejorando las características de seguridad de los vehículos, y promulgando leyes relacionadas con los principales riesgos y velando por su cumplimiento.

2.2.1.2 Principios básicos de seguridad vial

Los principios básicos de seguridad vial constituyen un marco conceptual integral que establece los fundamentos científicos y metodológicos para la prevención de lesiones y muertes en el sistema de transporte vial. Estos principios se organizan principalmente a través del Enfoque de Sistema Seguro y los Cinco Pilares de la Seguridad Vial, desarrollados por la (Organización Mundial de la Salud (2024)) y adoptados internacionalmente.

1. Enfoque de sistema seguro

El enfoque de sistema seguro constituye un conjunto de principios orientados a la protección de la vida y la salud humana, de tal forma que este fin sea la primera y más importante consideración al diseñar y operar un sistema de transporte. Este enfoque centra su foco en la vulnerabilidad del actor vial y parte de la premisa que ningún ser humano puede fallar, pero que es intolerable que pierda la vida o sufra lesiones graves por causa

de un siniestro vial.

El enfoque del sistema seguro marca un cambio de la atención exclusiva a la reducción de los accidentes a la eliminación de los muertos y los heridos graves, reconociendo que los sistemas de transporte deberían responder a las necesidades de los usuarios y perdonar el error humano.

2. Los cinco pilares de la seguridad vial (OMS)

Los cinco pilares de la OMS en materia de seguridad vial representan un marco integral para mejorar la seguridad en las carreteras a nivel mundial, abarcando aspectos críticos desde la gestión efectiva de la seguridad vial hasta la creación de infraestructuras seguras diseñadas para proteger a todos los usuarios de la vía.

- **Gestión de la seguridad vial** Implica establecer políticas, leyes y regulaciones sólidas para abordar los problemas de seguridad vial, así como la prestación de liderazgo en la coordinación de los esfuerzos de seguridad vial a nivel nacional.
- **Infraestructuras seguras:** Se refiere a la planificación y el diseño adecuados de las carreteras y calles, incluyendo la construcción y el mantenimiento de infraestructuras seguras para todos los usuarios de la vía, aportando mayor seguridad a los usuarios vulnerables: peatones, ciclistas y motociclistas.
- **Vehículos seguros:** Implica la promoción de vehículos seguros y la implementación de normas de seguridad y regulaciones para garantizar la fabricación y utilización de vehículos que cumplan con estándares de seguridad establecidos.
- **Comportamiento seguro de los usuarios:** Incluye promover y educar a los usuarios de la vía sobre la adopción de comportamientos seguros, como usar el cinturón de seguridad, respetar los límites de velocidad, abstenerse de conducir bajo los efectos del alcohol o las drogas, y respetar las normas de tráfico.
- **Respuesta tras los accidentes:** Implica el fortalecimiento de los sistemas de respuesta en caso de accidente, incluyendo servicios de emergencia médica y atención a las víctimas de los accidentes de tráfico, así como la implementación de programas de rehabilitación y apoyo a largo plazo.

3. Principios fundamentales del sistema seguro

El modelo del sistema seguro se compone de cuatro elementos principales: carreteras y márgenes más seguras (predecibles y tolerantes con los errores), velocidades seguras (adaptadas a la función y al nivel de seguridad de la carretera), vehículos seguros (que previenen los accidentes y protegen a los usuarios), y usuarios seguros (atentos y en buenas condiciones físicas que cumplen los reglamentos de tráfico). La combinación de las características de seguridad de la infraestructura, las de los vehículos y la velocidad de los vehículos involucrados en un accidente determina las fuerzas del impacto que experimentan los ocupantes durante el choque. Estas interacciones deben controlarse a fin de evitar lesiones graves y muertes.



Figura 2: Intervenciones prioritarias para la seguridad vial
Fuente: Imagen obtenida en la web

2.2.1.3 Componentes del sistema de tránsito (usuario, vehículo, vía, entorno)

El sistema de tránsito constituye un fenómeno complejo que involucra la interacción dinámica de múltiples elementos interdependientes. La simulación se define como representación dinámica de alguna parte del mundo real lograda mediante la construcción de un modelo computacional y moviéndolo a través del tiempo. Los modelos computacionales son ampliamente utilizados en el análisis de sistemas de tráfico y transporte. Los sistemas de transporte están caracterizados por varias características que los hacen difíciles de analizar, controlar y optimizar. Los sistemas a menudo cubren amplias áreas físicas, el número de participantes activos es alto, las metas y objetivos de los participantes no son necesariamente paralelos entre sí o con los del operador del sistema. Esta complejidad inherente ha llevado a los investigadores a desarrollar marcos conceptuales que permitan comprender y analizar los diferentes componentes que conforman el sistema de tránsito. La literatura científica ha identificado consistentemente cuatro componentes fundamentales que conforman el sistema de tránsito: el usuario, el vehículo, la vía y el entorno. Esta clasificación, conocida como el modelo de cuatro componentes, proporciona un marco analítico robusto para el estudio de la seguridad vial y la eficiencia del transporte.

Componente 1: Usuario del sistema

- **Definición y características:** Los usuarios de carreteras son el aspecto primario y más importante del sistema de transporte. Proporcionar las necesidades del usuario es la característica principal de un sistema de transporte sostenible. (Jameel y Evdorides (2018)) En el estudio del comportamiento del usuario de carreteras, los datos pueden utilizarse para explorar características del usuario de carretera, verificar teorías, o predecir el comportamiento del usuario de carretera. (Donmez et al. (2023))

- **Aspectos psicológicos y comportamentales:** Según (Fuller (2008)), el comportamiento de los usuarios de carreteras es un factor importante en la causación de accidentes. La psicología del tráfico, definida como “el estudio del comportamiento de los usuarios de carreteras y los procesos psicológicos subyacentes a ese comportamiento”, intenta identificar los determinantes del comportamiento del usuario de carreteras con el objetivo de desarrollar contramedidas efectivas contra accidentes.

El comportamiento del usuario de carreteras se considera el principal factor contribuyente a la mayoría de accidentes de carretera. Por lo tanto, los planes estratégicos de seguridad vial exitosos y efectivos se enfocan en mejorar el comportamiento del usuario de carreteras considerando siete factores de riesgo del usuario de carretera: conductores bajo efectos del alcohol, cinturones de seguridad, sistemas de retención infantil, gestión de velocidad, uso de cascos, uso de teléfono móvil mientras se conduce, y conducir bajo la influencia de drogas.

- **Usuarios vulnerables:** El concepto de usuarios vulnerables de carreteras se refiere a peatones y ciclistas (ciclistas y motociclistas) que son fácilmente heridos y muertos en un espacio vial dominado por automóviles. Esta categorización reconoce que ciertos usuarios del sistema de tránsito enfrentan riesgos desproporcionadamente altos debido a su exposición y vulnerabilidad física.

Componente 2: Vehículo

- **Conceptualización Tecnológica:** Los vehículos inteligentes y el transporte inteligente brindan oportunidades sin precedentes para mitigar la congestión del tráfico, ahorrar energía, reducir colisiones y mejorar el rendimiento. Las tecnologías clave de investigación y prácticas en este campo incluyen tecnologías avanzadas de vehículos, análisis de datos de alta resolución, nuevos paradigmas para servicios de movilidad y sistemas de múltiples sistemas.
- **Vehículos conectados:** La emergencia de los Sistemas de Transporte Inteligente (ITS) ha allanado el camino a nuevas perspectivas innovadoras para mejorar la seguridad, operación e impacto ambiental de las redes de transporte. Los vehículos conectados (CV), una iniciativa innovadora de “vehículos inteligentes”, emergen como la siguiente ola de tecnología para empoderar aún más a los viajeros. Los vehículos modernos incorporan sistemas de seguridad que se clasifican en dos categorías principales: seguridad activa (sistemas que previenen accidentes) y seguridad pasiva (sistemas que minimizan las consecuencias de los accidentes).

Componente 3: Vía (Infraestructura vial)

- **Definición y alcance:** La infraestructura vial consiste en la instalación de activos fijos incluyendo carreteras superficiales y ferrocarriles y terminales como paradas de autobús, terminales de camiones, estaciones de ferrocarril. Las operaciones de vehículos a lo largo de estos sistemas de transporte hacen que el tiempo de viaje se reduzca y genere empleo en el sector. (Global (2023))
- **Componentes físicos:** La infraestructura de tráfico se refiere a los componentes físicos de los sistemas de transporte, incluyendo segmentos de carretera, carriles dedicados

de autobús, señales de tráfico, paradas de autobús y adaptaciones adicionales diseñadas para facilitar el movimiento de vehículos y mejorar el flujo de tráfico.

Componente 4: Entorno

- **Conceptualización del entorno vial:** Los estudios sobre la seguridad de conducción en condiciones climáticas de lluvia, nieve y niebla pertenecen al área de investigación de riesgos de factores ambientales de tráfico. El entorno representa el conjunto de condiciones externas que influyen en la operación del sistema de tránsito. Los factores ambientales críticos incluyen condiciones meteorológicas (lluvia, nieve, niebla, viento), condiciones de iluminación (día, noche, crepúsculo), visibilidad (clara, reducida, nula) y temperatura (extrema fría, extrema caliente, moderada). Estos factores ambientales han sido identificados como contribuyentes significativos a los riesgos operacionales del tráfico.

Interacciones entre componentes

- **Enfoque de sistema seguro:** El enfoque de sistema seguro aboga por un sistema de transporte seguro para todos los usuarios de las carreteras. Este enfoque tiene en cuenta la vulnerabilidad de las personas a los traumatismos graves causados por el tránsito, y reconoce que, al concebir el sistema, debería tenerse en cuenta el error humano.
- **Prevención y control de riesgos:** La seguridad del tráfico vial puede asegurarse mediante la prevención y el control de los riesgos potenciales en las operaciones del tráfico vial. Los resultados muestran que los temas de investigación relevantes cubrieron principalmente los riesgos de conductores, vehículos, carreteras y el entorno de tráfico.

2.2.1.4 Factores de riesgo en la seguridad vial

Los factores de riesgo en seguridad vial son todas aquellas condiciones, circunstancias o elementos que incrementan la probabilidad de ocurrencia de un accidente de tránsito o que pueden agravar sus consecuencias, clasificándose tradicionalmente en tres categorías principales: factores humanos (como el consumo de alcohol, drogas, fatiga, distracción, exceso de velocidad, falta de experiencia del conductor y conducción imprudente), factores vehiculares (relacionados con las condiciones mecánicas, mantenimiento y características de seguridad del vehículo, incluyendo fallas en frenos, sistemas de iluminación y dispositivos de retención) y factores ambientales o de infraestructura (que abarcan las condiciones de la vía, señalización inadecuada, deterioro del pavimento, deficiente iluminación, condiciones climáticas adversas y diseño geométrico inapropiado de las carreteras), siendo esta clasificación tripartita fundamental para el desarrollo de estrategias integrales de prevención y gestión de la seguridad vial.




Figura 3: Factores de velocidad alta
Fuente: Imagen obtenida en la web

2.2.1.5 Accidentes de tránsito

Los accidentes de tránsito son eventos súbitos e inesperados que ocurren durante la circulación de vehículos en las vías públicas, caracterizándose por la colisión entre uno o más vehículos, o entre un vehículo y otros elementos del entorno vial como peatones, ciclistas, motociclistas, objetos fijos o animales, resultando en consecuencias que pueden incluir daños materiales a los vehículos involucrados, lesiones de diversa gravedad en las personas afectadas, discapacidades permanentes o muerte, así como impactos económicos significativos tanto para los individuos como para los sistemas de salud pública y la sociedad en general, constituyendo un problema de salud pública de alcance mundial que afecta aproximadamente a 1.19 millones de personas anualmente con desenlace fatal y entre 20 a 50 millones con traumatismos no mortales, representando la principal causa de mortalidad en niños y jóvenes de 5 a 29 años y generando costos equivalentes al 3 % del Producto Interno Bruto en la mayoría de los países. (Alvia Párraga y Linares Giler (2024).)



Figura 4: Estrategias fundamentales para prevenir accidentes
Fuente: Imagen obtenida en la web

2.2.1.6 Señalización vial y su rol en la seguridad

La señalización vial constituye el conjunto sistemático de dispositivos visuales, marcas, símbolos, colores y mensajes estandarizados que se instalan estratégicamente en las vías públicas para transmitir información esencial a los usuarios del sistema vial, cumpliendo un rol fundamental en la seguridad vial al guiar, advertir, regular y ordenar el tránsito vehicular y peatonal mediante tres funciones principales: informativa (proporcionando orientación sobre destinos, distancias, servicios y ubicaciones), preventiva (alertando sobre peligros potenciales, condiciones especiales de la vía o situaciones que requieren precaución) y restrictiva (estableciendo limitaciones, prohibiciones y regulaciones que deben ser respetadas obligatoriamente), utilizando un lenguaje visual uniforme y comprensible que permite la interpretación rápida y precisa de las indicaciones, contribuyendo significativamente a la reducción de accidentes de tránsito, el mejoramiento del flujo vehicular, la protección de usuarios vulnerables como peatones y ciclistas, y el establecimiento de un sistema de transporte seguro, eficiente y predecible que facilita la toma de decisiones correctas por parte de conductores y peatones en tiempo real. (Cedeño-Alcívar y Mogrovejo (2023))



Figura 5: Señalización vial y su rol en la seguridad
Fuente: Imagen obtenida en la web

2.2.1.7 Manual de dispositivos de control de tránsito automotor 2024

El Manual de Dispositivos de Control de Tránsito Automotor para Calles y Carreteras constituye un documento técnico normativo oficial de carácter obligatorio que establece los lineamientos, criterios, especificaciones y procedimientos estandarizados para el diseño, instalación, ubicación y mantenimiento de todos los dispositivos destinados al control y regulación del tránsito vehicular y peatonal, incluyendo señales verticales (reglamentarias, preventivas e informativas), marcas horizontales en el pavimento, semáforos y dispositivos auxiliares, con el objetivo fundamental de lograr la uniformidad necesaria e imprescindible en la aplicación de estos elementos de control a nivel

nacional, garantizando que cumplan con requisitos esenciales como la capacidad de llamar positivamente la atención y ser visibles, transmitir mensajes claros y concisos, permitir tiempo adecuado de percepción y reacción a los usuarios, infundir respeto y ser obedecidos, y mantener coherencia y consistencia en su implementación, contribuyendo así de manera significativa al mejoramiento de la seguridad vial, la eficiencia en la circulación del tránsito, la reducción de accidentes de tránsito y la protección de la integridad física de todos los usuarios de las vías urbanas y carreteras del país.



Figura 6: Presentación del Manual

Fuente: Obtenido de Manual de Dispositivos de Control del Tránsito Automotor (2024)

2.2.1.8 Señales verticales

Las señales verticales constituyen dispositivos de control del tránsito instalados estratégicamente al costado de las vías o suspendidos sobre ellas mediante postes, pórticos, banderolas u otras estructuras de soporte, que tienen por finalidad fundamental reglamentar el tránsito, prevenir situaciones de riesgo e informar a los usuarios de las vías públicas (conductores, peatones y ciclistas) mediante símbolos estandarizados, leyendas, pictogramas y códigos de colores específicos establecidos en los manuales técnicos correspondientes, clasificándose funcionalmente en tres categorías principales: señales reglamentarias o reguladoras (que notifican sobre limitaciones, prohibiciones, restricciones, obligaciones y autorizaciones cuyo incumplimiento constituye infracción a las normas de tránsito), señales preventivas o de advertencia (que alertan sobre la existencia y naturaleza de riesgos, peligros o situaciones imprevistas presentes en la vía o zonas adyacentes de manera permanente o temporal), y señales informativas (que guían y orientan a los usuarios proporcionando datos sobre destinos, distancias, servicios, puntos de interés turístico, nombres de calles y rutas), cumpliendo requisitos técnicos esenciales como visibilidad diurna y nocturna mediante materiales retroreflectivos,

dimensionamiento apropiado según la velocidad de la vía, ubicación dentro del cono de atención visual del conductor, resistencia a condiciones climáticas adversas y uniformidad en su aplicación, contribuyendo de manera significativa al mejoramiento de la seguridad vial, la fluidez del tráfico y la reducción de accidentes de tránsito. Manual de Dispositivos de Control del Tránsito Automotor (2024)



Figura 7: Señalización vertical R-27 (NE)

Fuente: Imagen propia

- **Estandarización del diseño:** La coherencia visual en aspectos morfológicos, cromáticos, dimensionales y simbólicos resulta esencial para garantizar la comprensión inmediata y efectiva del mensaje por parte de los usuarios viales. Este Manual establece especificaciones detalladas sobre configuración y proporciones de las señales, incorporando además un sistema tipográfico normalizado que contempla diversas escalas de caracteres y directrices para su aplicación correcta, incluyendo el espaciado interletral apropiado.
- **Transmisión eficaz de mensajes viales:** Cada dispositivo de señalización debe comunicar información precisa e inconfundible a los usuarios del sistema de transporte, empleando iconografía normalizada y/o textos explicativos compuestos por elementos alfanuméricos. La consistencia comunicativa exige que circunstancias análogas sean representadas mediante señalética idéntica, independientemente de su ubicación geográfica. Se privilegia la simbología sobre los textos debido a su mayor velocidad de procesamiento cognitivo, conforme a las especificaciones del presente Manual. La concordancia entre elementos simbólicos y textuales es obligatoria cuando coexisten en una misma señal. Las abreviaciones de unidades métricas deben ajustarse al Sistema Internacional de Unidades,
- **Normativa tipográfica diferenciada:** En señalizaciones reglamentaria y preventiva, tanto los textos principales como los complementarios deben emplear caracteres mayúsculos, salvo excepciones específicamente contempladas. Para señalización

informativa, la selección entre mayúsculas y minúsculas se determina según el tamaño del carácter. La preferencia por caracteres minúsculos en señales informativas se fundamenta en investigaciones que demuestran su superior legibilidad en contextos viales. La implementación de simbología novedosa en determinadas localidades debe acompañarse temporalmente de placas educativas explicativas, de formato rectangular subordinado al ancho de la señal principal y cromáticamente coherente, con vigencia máxima de tres años.

Ubicación lateral de las señalizaciones:




Figura 8: Ubicación correcta de la señalización vertical

Fuente: Imagen obtenida de Manual de Dispositivos de Control del Tránsito Automotor (2024)

Ubicación longitudinal y distancias de lectura :




Figura 9: Ubicación longitudinal y distancias de lectura

Fuente: Imagen obtenida de Manual de Dispositivos de Control del Tránsito Automotor (2024)

1. Señales reguladoras o de reglamentación

Las señales reguladoras o de reglamentación constituyen dispositivos de control del tránsito de cumplimiento obligatorio que tienen por finalidad notificar expresamente a los usuarios de las vías públicas sobre las limitaciones, restricciones, prohibiciones,

obligaciones y autorizaciones específicas que rigen el uso de la infraestructura vial, estableciendo el marco normativo que debe ser respetado durante la circulación vehicular y peatonal, cuya transgresión constituye una infracción a las disposiciones legales vigentes en materia de tránsito y transporte terrestre, caracterizándose por su forma circular inscrita en placas cuadradas o rectangulares (con excepción de la señal "PARE" de forma octogonal y CEDA EL PASO de configuración triangular), empleando códigos cromáticos específicos como el rojo para prohibiciones, azul para obligaciones, y combinaciones estandarizadas que garantizan su reconocimiento inmediato, contribuyendo al ordenamiento del flujo vehicular, la prevención de conflictos viales y el mantenimiento de la seguridad en el sistema de transporte.

- **Señales de prioridad:** La señal (R-1) PARE dispone que el conductor de un vehículo se detenga antes de cruzar una intersección, y debiendo determinarse su ubicación de acuerdo al estudio de ingeniería vial antes indicado, puesto que su uso indiscriminado puede afectar negativamente a su credibilidad, y en lugar de ayudar a la seguridad vial en una intersección puede generar inseguridad. La señal (R-2) CEDA EL PASO dispone que el conductor de un vehículo que circula por una vía de menor prioridad, (vía secundaria o auxiliar) permita el paso de otro vehículo que circula por una vía de mayor prioridad (vía principal). Su ubicación está en función de la visibilidad del que circula por la vía de menor prioridad y la distancia necesaria para ceder el paso antes de entrar a una intersección. En caso contrario, debe emplearse la señal (R-1) PARE.



Figura 10: Señales de prioridad R-1 y R-2

Fuente: Imagen obtenida de Manual de Dispositivos de Control del Tránsito Automotor (2024)

- **Señal de prohibición:** Se usan para prohibir o limitar el tránsito de ciertos tipos de vehículos o determinadas maniobras. Se representa mediante un círculo blanco con orla roja cruzado por una diagonal también roja, descendente desde la izquierda formando un ángulo de 45° con la horizontal. La señal (R-28) NO ESTACIONAR NI DETENERSE es una excepción en la cual hay dos diagonales. Cuando una prohibición afecta sólo a un tipo de vehículo, debe agregarse un mensaje que lo identifique claramente. A modo de ejemplo, si la prohibición afecta únicamente a buses, la señal se compone del símbolo correspondiente y el mensaje "BUSES" ubicada en la parte superior. Cuando se trate de prohibiciones a la circulación que apliquen a uno o más tipos de vehículos, o a vehículos y peatones, las correspondientes señales pueden presentarse agrupadas en un mismo poste, en placa de color blanco de fondo.

■ Señal de prohibición de maniobras y giros



Figura 11: Señales de prohibición de maniobras y giros

Fuente: Imagen obtenida de Manual de Dispositivos de Control del Tránsito Automotor (2024)

■ Señal de prohibición por pase de vehículos



Figura 12: Señales de prohibición de paso por clase de vehículo

Fuente: Imagen obtenida de Manual de Dispositivos de Control del Tránsito Automotor (2024)

2. Señales de prevención

Las señales de prevención o preventivas son dispositivos de advertencia temprana instalados estratégicamente en las vías con el propósito fundamental de alertar e informar a los conductores y demás usuarios sobre la existencia, proximidad y naturaleza específica de riesgos, peligros potenciales, condiciones geométricas especiales de la carretera o situaciones imprevistas que puedan presentarse de manera permanente o temporal en la vía o en sus zonas adyacentes, permitiendo a los usuarios adoptar oportunamente las medidas de precaución necesarias tales como reducción de velocidad, cambio de carril, incremento de la distancia de seguimiento o ejecución de maniobras evasivas para salvaguardar su propia integridad física y la de otros usuarios vulnerables del sistema vial, caracterizándose por su forma romboidal (cuadrado rotado 45 grados) con fondo amarillo y símbolos o leyendas en color negro, ubicándose a distancias calculadas que permitan tiempo suficiente de percepción, reacción y respuesta ante la condición advertida.

Señales preventivas por características de la superficie de rodadura




Figura 13: Señales preventivas por características de la superficie de rodadura
Fuente: Imagen obtenida de Manual de Dispositivos de Control del Tránsito Automotor (2024)

Señales preventivas por características operativas de la vía




Figura 14: Señales preventivas por características operativas de la vía
Fuente: Imagen obtenida de Manual de Dispositivos de Control del Tránsito Automotor (2024)

3. Señales de información

Las señales de información constituyen dispositivos orientadores y educativos que tienen como función principal guiar, dirigir y proporcionar datos útiles y relevantes a los usuarios de las vías para facilitarles el proceso de navegación y toma de decisiones durante sus desplazamientos, suministrando información sobre destinos, direcciones, distancias kilométricas a poblaciones y servicios, nombres de calles y avenidas, numeración de rutas, ubicación de sitios de interés turístico, histórico, cultural o recreativo, servicios al usuario como estaciones de combustible, restaurantes, hoteles y hospitales, así como datos geográficos y de orientación general que contribuyen a mejorar la eficiencia del viaje y la experiencia del usuario, caracterizándose por su forma rectangular con mayor dimensión horizontal, empleando fondos verdes para destinos locales, azules para rutas principales y autopistas, cafés para sitios turísticos, y letras blancas para garantizar contraste y legibilidad óptima tanto diurna como nocturna.

4. Señalización para estaciones de peaje y pesaje

La señalización de estaciones de peaje y pesaje comprende un sistema especializado de dispositivos informativos y reguladores diseñados específicamente para orientar, dirigir

y controlar el flujo vehicular en las proximidades e instalaciones de puntos de cobro de peajes y estaciones de verificación de peso y dimensiones vehiculares, proporcionando instrucciones claras sobre la aproximación obligatoria, selección de carriles apropiados según el tipo de vehículo y método de pago, velocidades permitidas en la zona de operación, restricciones especiales para vehículos de carga, procedimientos de detención y avance, así como información sobre tarifas aplicables y sistemas de pago electrónico disponibles, utilizando configuraciones rectangulares con códigos cromáticos específicos, símbolos universalmente reconocidos y leyendas en múltiples idiomas cuando sea necesario, garantizando la operación segura, eficiente y ordenada de estas instalaciones críticas para la gestión del tráfico y el control del transporte de mercancías.

5. Señalización para rampas de emergencia

Las señales para rampas de emergencia constituyen dispositivos de seguridad vial especializados que identifican, señalizan y proporcionan instrucciones específicas sobre la ubicación, acceso y uso correcto de las vías de escape o rampas de frenado de emergencia, instaladas estratégicamente en tramos de carretera con pendientes pronunciadas, curvas peligrosas o sectores de alta montaña donde los vehículos, particularmente los de gran tonelaje, pueden experimentar fallas en los sistemas de frenado o pérdida de control, indicando claramente la distancia a la siguiente rampa disponible, las condiciones de acceso, restricciones de uso exclusivo para situaciones de emergencia real, velocidades recomendadas de ingreso, características técnicas de la superficie de frenado y advertencias sobre las consecuencias del uso indebido, empleando colores de alta visibilidad como amarillo fluorescente o naranja, símbolos gráficos explicativos y materiales retroreflectivos de máxima intensidad para garantizar su detección oportuna bajo cualquier condición climática o de visibilidad, constituyendo elementos vitales para la prevención de accidentes graves en zonas de topografía compleja.




Figura 15: Señalización para rampas de emergencia

Fuente: Imagen obtenida de Manual de Dispositivos de Control del Tránsito Automotor (2024)

2.3. Marco conceptual

2.3.1. Técnicas de inteligencia artificial

2.3.1.1 Machine Learning y Deep Learning

1. Introducción al Machine Learning

El aprendizaje automático o Machine Learning (ML) representa una especialización dentro de la inteligencia artificial que dota a los sistemas computacionales de la habilidad para adquirir conocimiento y optimizar su desempeño de manera autónoma mediante la experiencia acumulada, sin requerir programación explícita para cada tarea específica. De acuerdo con Géron (2019), este campo disciplinar se enfoca en desarrollar algoritmos capaces de acceder a conjuntos de datos y emplearlos como base para un proceso de aprendizaje autónomo.

Los sistemas computacionales poseen la habilidad inherente de desarrollar procesos de autoaprendizaje y autoprogramación mediante la asimilación de experiencias previas, optimizando continuamente su rendimiento basándose en resultados históricos de forma completamente automatizada (Lasse (2018).)

2. Tipos de aprendizaje en Machine Learning

Conforme a lo establecido por Lasse (2018), el proceso de aprendizaje automatizado en redes neuronales puede implementarse mediante diversas metodologías que se categorizan en tres enfoques principales: supervisado, no supervisado y por refuerzo.

- **Aprendizaje Supervisado:** La metodología emplea conjuntos de datos previamente etiquetados para que el algoritmo establezca correspondencias entre variables de entrada y resultados esperados. Las aplicaciones principales abarcan tareas de clasificación y regresión.
- **Aprendizaje No Supervisado:** Esta aproximación procesa información sin etiquetas previas, descubriendo estructuras y patrones inherentes en los datos. Sus aplicaciones frecuentes incluyen agrupamiento de datos (clustering), reducción dimensional y identificación de anomalías.
- **Aprendizaje por Refuerzo:** El sistema desarrolla conocimiento mediante interacción continua con un ambiente variable, recibiendo señales de retroalimentación positiva o negativa según la calidad de sus decisiones.

3. Deep Learning - Fundamentos

El aprendizaje profundo o Deep Learning (DL) constituye una rama especializada del Machine Learning que emplea arquitecturas de redes neuronales artificiales multicapa (denominadas "profundas" por su estructura) para extraer representaciones y características de alto nivel a partir de información compleja Goodfellow et al. (2016).

4. Ventajas del Deep Learning

- **Extracción automática de características:** Suprime la necesidad de extracción manual de características, desarrollando representaciones jerárquicas de forma directa desde los datos originales.

- **Capacidad de escalamiento:** El desempeño se incrementa proporcionalmente con mayores volúmenes de datos y capacidad de procesamiento, contrastando con otros algoritmos que presentan saturación en su rendimiento.
- **Adaptabilidad:** Los modelos preentrenados pueden modificarse eficazmente para nuevas tareas relacionadas mediante técnicas de transfer learning.
- **Versatilidad:** Se adapta a múltiples tipologías de datos (imágenes, texto, audio, series temporales) empleando arquitecturas especializadas.

2.3.1.2 Redes neuronales artificiales (RNA)

1. Definición y analogía biológica

La compleja y fascinante arquitectura del cerebro humano, constituida por billones de neuronas interconectadas, presenta la capacidad de transmitir información entre sus múltiples células nerviosas mediante el fenómeno sináptico. Las neuronas biológicas se constituyen por tres componentes fundamentales: el soma o cuerpo celular, las dendritas que operan como receptores de señales entrantes, y el axón que funciona como conductor de información de salida. El proceso sináptico ocurre en el punto de encuentro entre una dendrita y el axón de otra neurona. Cuando se manifiesta un estímulo, ya sea eléctrico o de otra naturaleza, en estas conexiones se producen intercambios de sustancias, reacciones bioquímicas y liberación de neurotransmisores. Estos compuestos químicos, dependiendo de su tipo, poseen la capacidad de excitar o inhibir las células receptoras Becerra (2014).

La analogía biológica se fundamenta en:

- Las neuronas artificiales emulan el comportamiento de las neuronas biológicas.
- Las conexiones ponderadas representan las sinapsis neuronales.
- La función de activación modela el potencial de acción de las neuronas.
- La organización en capas refleja la estructura de diferentes áreas cerebrales.

2. La neurona artificial

Las redes neuronales artificiales constituyen modelos computacionales basados en la estructura y operación del cerebro humano, conformados por capas de neuronas interconectadas. Estos sistemas se emplean para procesar información, identificar patrones complejos en conjuntos de datos y realizar predicciones, desarrollándose como emulación del funcionamiento y comportamiento de las redes neuronales biológicas. Las RNA se organizan en capas y desarrollan la capacidad de identificar relaciones y patrones complejos, para posteriormente aproximarlos a funciones matemáticas y generar 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:

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

Donde:

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




Figura 16: Modelo matemático de una neurona artificial
Fuente: Elaboración propia

3. Funciones de activación Las funciones de activación representan elementos fundamentales que establecen si una neurona debe activarse, introduciendo no-linealidades esenciales en el sistema. Las funciones de activación más utilizadas 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 incorpora dos procesos esenciales, según describen Chollet y Allaire (2018):

- **Propagación hacia adelante (Forward Propagation):**

- Las entradas se introducen en la red y se propagan através de todas las capas.
- Cada neurona ejecuta su función de transformación correspondiente.
- Se genera una predicción en la capa de salida.

- **Retropropagación (Backpropagation):**

- Se determina el error entre la predicción y el valor objetivo.
- Este error se propaga hacia atrás através de la arquitectura de red.
- Los pesos se modifican proporcionalmente a su contribución al error.
- Se emplea el descenso del gradiente para minimizar la función de pérdida.

2.3.1.3 Tipos de redes neuronales

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

1. Redes Neuronales Feedforward (FFNN)

Las redes feedforward o de alimentación directa representan la arquitectura más básica, donde la información fluye unidireccionalmente, desde la entrada hacia la salida, sin bucles ni retroalimentación. Según Da Silva et al. (2017), estas redes se componen de:

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

2. Redes Neuronales Convolucionales (CNN)

Estas arquitecturas fueron diseñadas para replicar el funcionamiento de las neuronas de la corteza visual cerebral, proporcionando a las computadoras la habilidad de "percibir visualmente". Esta característica las ha establecido como una de las técnicas más empleadas en el ámbito del Aprendizaje Automático para resolver problemas de visión artificial, mediante el reconocimiento de objetos en imágenes y videos Núñez (2016).

Las CNN constituyen una clase de red que funciona bajo un paradigma de aprendizaje supervisado e incorpora múltiples capas ocultas, estructuradas jerárquicamente y especializadas en funciones específicas. Como ejemplo, las capas iniciales pueden detectar elementos básicos como líneas, curvas y formas, mientras que las capas más profundas se especializan en el reconocimiento de patrones considerablemente más complejos, como rostros humanos, vehículos, animales y diversos objetos.

Una CNN típica incorpora:

- **Capas convolucionales:** Implementan 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:** Ejecutan la clasificación basada en las características extraídas.




Figura 17: Arquitectura de una CNN
Fuente: Adaptado de Vizcaya et al. (2017)

3. Redes Neuronales Recurrentes (RNN)

Las Redes Neuronales Recurrentes se especializan en procesar datos secuenciales, como series temporales o texto. Según Yu et al. (2019), las RNN incorporan conexiones recurrentes que permiten la persistencia de información, creando una forma de memoria que captura dependencias temporales.

4. Redes neuronales Autoencoders

Los autoencoders constituyen 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.

2.3.1.4 Profundización en las Redes Neuronales Convolucionales (CNN):

Funcionamiento de las CNN

Las CNN procesan una entrada constituida por una imagen. Esta representación visual puede modelarse como una matriz multidimensional que se procesa mediante una secuencia de filtros denominados kernels. Una imagen presenta ancho (correspondiente al número de columnas) y altura (equivalente al número de filas), similar a una matriz. No obstante, a diferencia de las matrices convencionales, las imágenes incorporan una dimensión adicional llamada profundidad, determinada por sus canales cromáticos que contienen los valores numéricos de los 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 posee un canal único. Los valores píxel en estas imágenes típicamente oscilan entre 0 y 255, y para optimizar el procesamiento, es recomendable normalizarlos a un rango entre 0 y 1, dividiéndolos por 255 Nizama Yamunaque (2022).

A. Operación de convolución y Kernels

Una operación convolucional implica la agregación de elementos de una matriz resultado, obtenida mediante la multiplicación elemento por elemento de dos matrices: una que representa una sección de la imagen original y otra correspondiente a un kernel. Un kernel o filtro puede definirse como una matriz de dimensiones pequeñas (en relación con la matriz de imagen) empleado para diversas operaciones como enfocar, desenfocar, suavizar, o detectar características como líneas, formas y bordes. Este kernel se desplaza secuencialmente, píxel por píxel, sobre todas las neuronas de la capa de entrada, desde izquierda a derecha y de arriba hacia abajo, generando una nueva matriz de salida que constituye una capa oculta neuronal.

La operación convolucional constituye el elemento fundamental de las CNN. Según Yamashita et al. (2018), esta operación comprende:

- 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:

$$(I * K)(i, j) = \sum_m \sum_n I(i + m, j + n) \cdot K(m, n) \quad (2)$$

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. Función de activación-ReLu

De manera análoga al proceso sináptico en sistemas biológicos, las Redes Neuronales Artificiales (RNA) incorporan una función de activación que modifica el valor neuronal con el propósito de activarla y transmitir un resultado a la conexión subsiguiente, equivalente a la sinapsis. Esta función determina si el valor neuronal, representado por los valores de la matriz resultante, supera un umbral establecido para ser transmitido a la capa siguiente. En el contexto de las CNN, la función de activación que ha demostrado mayor eficacia y mejores resultados es la Unidad Lineal Rectificada, conocida como ReLU (Rectified Linear Unit) Ramachandran et al. (2017), definida matemáticamente como:

$$f(x) = \max(0, x) = \begin{cases} 0 & , \text{ si } x < 0 \\ x & , \text{ si } x \geq 0 \end{cases} \quad (3)$$

La figura N° 18 ilustra la aplicación de la función de activación ReLU a la matriz de salida presentada. 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° 18, 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

$f(x) = \max(0, x)$
 $\longrightarrow$

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

Figura 18: Aplicación de la función de activación ReLU
Fuente: Elaboración propia

C. Pooling- Agrupación

Representa una técnica esencial para reducir las dimensiones espaciales de una imagen. Su objetivo principal consiste en disminuir el número de neuronas (píxeles) y simplificar los cálculos antes de una nueva convolución. Este procedimiento involucra la consolidación de múltiples píxeles en uno solo, conservando la información más relevante.

Existen diferentes variantes de pooling, incluyendo el Max Pooling (que selecciona el valor máximo dentro de una subregión píxel), el Min Pooling (que elige el valor mínimo) y el Average Pooling (que computa el valor promedio). Sin embargo, el Max Pooling sobresale como una técnica de submuestreo altamente efectiva en las Redes Neuronales Convolucionales (RNC) para comprimir las características de una región. Esta operación consiste en identificar el valor máximo dentro de una muestra y emplear dicho valor como resumen representativo de las características presentes en esa zona. Al aplicar un Max Pooling de 2x2, se logra reducir el tamaño de la imagen a la mitad.

La figura N° 19 ilustra un ejemplo de la aplicación de un Max Pooling de 2x2 a la matriz de salida obtenida en la Figura N° 18. 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.




Figura 19: Aplicación de un Max Pooling de 2x2
Fuente: Elaboración propia

En síntesis, después de aplicar un kernel de 3x3 y un Max Pooling de 2x2 a nuestra imagen original de 6x6, se produce una imagen resultante de 2x2 que encapsula información procesada y relevante de la imagen inicial. Esta información resulta fundamental para la identificación y el reconocimiento de patrones de formas u objetos. Como se mencionó previamente, 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.

D. Síntesis del proceso de una CNN

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 conjunto de filtros (kernels), la aplicación de una función de activación y una operación de Max-Pooling. A medida que se ejecutan 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° 1 presenta 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 1: 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 original de 48x48 píxeles en escala de grises (48x48x1) contiene 2,304 unidades de información o neuronas. En el procedimiento 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 20: Ejemplo de las capas de agrupamiento
Fuente: Adaptado de Vizcaya et al. (2017)

2.3.1.5 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 cuantifica la proporción de predicciones correctas sobre el total de instancias evaluadas. Aunque es ampliamente utilizada, presenta limitaciones significativas en conjuntos de datos desbalanceados Brownlee (2020).

$$\text{Exactitud} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

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

$$\text{Precisión} = \frac{TP}{TP + FP} \quad (5)$$

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

$$\text{Sensibilidad} = \frac{TP}{TP + FN} \quad (6)$$

4. Especificidad: La especificidad cuantifica 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).

$$\text{Especificidad} = \frac{TN}{TN + FP} \quad (7)$$

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.

$$\text{F1-Score} = 2 \times \frac{\text{Precisión} \times \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}} \quad (8)$$

2.3.1.6 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 21: Representación de la arquitectura Yolo V.8
Fuente: Adaptado de Vizcaya et al. (2017)

- **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 22: Representación de la arquitectura Faster-RCNN
Fuente: Adaptado de 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.

2.3.1.7 YOLO: You Only Look Once

1. Principios Fundamentales de YOLO

YOLO (You Only Look Once) representa un algoritmo revolucionario de detección de objetos en tiempo real desarrollado inicialmente por Joseph Redmon et al. en 2015, que contrario a 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.

2.3.1.8 Librerías de YOLO para el modelo de tráfico vehicular

La librería Ultralytics YOLO, junto con Matplotlib, Seaborn, Pandas, Collections, Defaultdict, Sklearn y TQDM, constituyen una implementación moderna del algoritmo 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.

3. MARCO METODOLÓGICO

3.1. Enfoque de la investigación

La presente investigación adopta un enfoque **cuantitativo**, dado que se orienta a la recolección, procesamiento y análisis de datos numéricos obtenidos a partir de experimentos controlados, entrenamientos computacionales y validaciones de desempeño de un modelo basado en inteligencia artificial. Este enfoque permite medir de forma objetiva el rendimiento del sistema de detección de señalizaciones verticales mediante métricas estadísticas como precisión, recall, mAP@0.5 y tiempos de inferencia, las cuales fueron obtenidas a través de pruebas sistemáticas y replicables.

Asimismo, se aplicaron técnicas propias del análisis **cuantitativo** como el monitoreo de curvas de pérdida durante el entrenamiento, el uso de algoritmos de EarlyStopping para evaluar la convergencia del modelo, y la validación cruzada mediante conjuntos de datos predefinidos. Estas estrategias garantizan la validez interna y externa de los resultados, permitiendo contrastar las hipótesis formuladas a través de evidencia empírica cuantificable.

En ese sentido, el enfoque **cuantitativo** proporciona el marco idóneo para analizar con rigurosidad el impacto de las técnicas de inteligencia artificial aplicadas a la mejora de la seguridad vial, al ofrecer datos precisos y verificables sobre el desempeño del sistema propuesto.

3.2. Alcance de la investigación

La presente investigación se enmarca dentro del alcance **explicativo**, ya que no solo se limita a describir o correlacionar variables, sino que busca identificar, analizar y comprender las causas que determinan el funcionamiento efectivo de un modelo de inteligencia artificial en la mejora de la seguridad vial. A través del diseño, entrenamiento y validación de un sistema de detección automatizada de señalizaciones verticales, se busca explicar cómo y por qué el uso de redes neuronales convolucionales (CNN) puede generar una respuesta tecnológica eficiente para reducir riesgos en el tránsito urbano.

El carácter **explicativo** de este estudio se evidencia en el análisis causal entre el comportamiento del modelo y las condiciones del entorno vial (tipo de señal, deterioro, ubicación, iluminación), así como en la evaluación de la efectividad del sistema de alertas por voz sobre la percepción de riesgo en conductores. De esta manera, la investigación permite no solo validar una hipótesis técnica, sino también comprender las dinámicas que permiten que una herramienta basada en inteligencia artificial incida positivamente en contextos reales de seguridad vial.

3.3. Diseño de la investigación

De acuerdo al diseño de la investigación, la investigación es **no experimental**, ya que no se manipulan deliberadamente las variables, ni se controla el entorno en el que se desarrollan

los fenómenos observados. En lugar de ello, se analizan y evalúan los resultados tal como se presentan en contextos reales o simulados, con el objetivo de observar el comportamiento del sistema propuesto bajo condiciones naturales de funcionamiento.

En este estudio no se asignan tratamientos ni se reorganizan variables de forma intencional, sino que se entrena y valida un modelo de detección de señales verticales utilizando un conjunto de datos preexistente, complementado con recorridos de simulación vehicular en escenarios urbanos reales de la ciudad de Ayacucho. Las condiciones del entorno como el tipo de vía, estado de las señalizaciones, iluminación o interferencias visuales no son modificadas, sino documentadas y consideradas como parte del contexto de análisis.

3.4. Población y muestra

3.4.1. Población

La población del estudio está constituida por el conjunto total de 3,000 imágenes de señalizaciones verticales capturadas en las vías principales de la ciudad de Ayacucho (Calle Nazareno, Jr. Carlos F. Vivanco, Jr. Libertad, Av. Mariscal Cáceres, Jr. Sol, Jr. Garcilaso de la Vega, Jr. Callao, Jr. Lima, Jr. San Martín, Jr. Tres Máscaras, Jr. 02 de Mayo, Jr. Cusco, Jr. Arequipa, Jr. Bellido, Jr. Grau, Av. Independencia, Av. 26 de Enero, Jr. Garcilazo de la Vega, Jr. Mario Ramos, Jr. Huanta, Av. Los Pinos, Jr. Asamblea, Jr. Sucre, Jr. Francisco Pizarro.). Estas imágenes fueron obtenidas mediante un dispositivo de celular mediante observación sistemática no participante en diferentes puntos estratégicos a lo largo de la vía. La población incluye registros fotográficos de las 14 señalizaciones basadas en el Manual de Dispositivos de Control del Tránsito Automotor (2024). 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.

3.4.2. Muestra

La muestra fue seleccionada mediante un muestreo no probabilístico de tipo intencional, conformada por 2,250 imágenes seleccionadas a partir de una población total de 3,000 fotografías capturadas durante recorridos urbanos. Los criterios de inclusión se centraron en garantizar la variabilidad y representatividad de las señalizaciones verticales, considerando aspectos como la distancia (cercanas y lejanas), la presencia de elementos superpuestos (como ramas, hojas o vehículos), así como condiciones reales del entorno urbano. Además, se aseguró que todas las imágenes cumplieran con los estándares técnicos necesarios para el entrenamiento efectivo de redes neuronales artificiales, en cuanto a resolución, nitidez y visibilidad. Este tipo de muestreo permitió capturar la heterogeneidad visual del contexto vial y asegurar la robustez del modelo ante escenarios diversos.

3.5. Hipótesis

3.5.1. Hipótesis general

Las técnicas de inteligencia artificial, basadas en redes neuronales convolucionales (CNN) permiten mejorar significativamente, la seguridad vial en las vías principales de la ciudad

de Ayacucho.

3.5.2. Hipótesis específicas

1. La arquitectura del modelo, basado en redes neuronales convolucionales (CNN), permite la detección , clasificación de 14 señalizaciones verticales basado en el Manual de dispositivos de control del tránsito automotor
2. El entrenamiento del modelo , basado redes neuronales convolucionales (CNN) logra una mayor precisión de clase, recall y velocidades de inferencia ultrarrápidos, evitando el sobreajuste.
3. La implementación del modelo, basado en redes neuronales convolucionales (CNN) permite el desarrollo de un software para la detección automatizada de señalizaciones verticales, integrando un sistema de alertas por voz optimizado que garantice una reproducción inmediata y sincrónica, fundamental para la emisión oportuna de advertencias en materia de seguridad vial.

3.6. Operacionalización de variables

3.6.1. 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): Técnicas de inteligencia artificial** : Es el factor que el investigador manipula o controla para observar su efecto en otra variable.
- **Variable dependiente (Y): Seguridad Vial** :Es el factor que el investigador mide y se espera que sea afectado por la manipulación de la variable independiente.

3.7. Técnicas e instrumentos.

3.7.1. Técnicas de recolección

Para el desarrollo de la presente investigación se emplearon diversos métodos orientados a la recolección y análisis de la información, así como a la construcción y validación del modelo basado en redes neuronales convolucionales, utilizando la arquitectura YOLO. A continuación, se detallan las técnicas específicas aplicadas en cada etapa del estudio, desde el procesamiento de datos hasta la evaluación del desempeño del sistema propuesto.

1. **Revisión bibliográfica y documental:** La presente investigación se fundamenta en la revisión y análisis crítico de literatura especializada relacionada con visión artificial, arquitecturas de redes neuronales convolucionales (CNN) para la mejorar la

seguridad vial, como la detección de las señalizaciones verticales. Esta recopilación bibliográfica se llevó a cabo mediante el acceso a repositorios académicos y bases de datos científicas reconocidas, como IEEE Xplore, Google Scholar, Scopus, Springer y, complementariamente, Sci-Hub. Asimismo, se consideraron libros especializados, artículos técnicos y documentos normativos relevantes para el campo de la inteligencia artificial aplicada a la seguridad vial. Esta revisión permitió establecer un marco teórico sólido que orientó el diseño metodológico y técnico del modelo propuesto, asegurando que su desarrollo esté respaldado por enfoques actualizados y validados científicamente.

2. **Análisis exploratorio de datos (EDA):** El análisis exploratorio de datos (EDA) permitió comprender la estructura, distribución y calidad del conjunto de imágenes utilizado para entrenar y validar el modelo de detección de señalizaciones verticales. Este proceso fue esencial para identificar patrones, anomalías y relaciones dentro del dataset, garantizando así una base sólida para el entrenamiento del modelo basado en la arquitectura YOLOv8.
3. **Desarrollo y entrenamiento del modelo basado en CNN:** Se implementó un sistema de redes neuronales convolucionales con YOLO para la identificación y categorización de 14 señalizaciones verticales, 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 y la implementación del modelo se realizó en las principales vías de la ciudad de Ayacucho, para medir su funcionamiento en escenarios reales. Se emplearán equipos de registro visual como cámaras con alta definición.

3.7.2. 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 señalizaciones:**
 - **Dispositivo móvil Samsung Galaxy S-23:** Es un smartphone de gama alta equipado con una cámara trasera principal de 50 MP, diseñada para capturar imágenes con gran nivel de nitidez y detalle. Su sistema de triple cámara permite adaptarse a distintos tipos de escena, incluyendo tomas a distancia, ángulos amplios y condiciones de baja iluminación, gracias a su lente ultra gran angular y su teleobjetivo con zoom óptico 3x. Las imágenes pueden ser capturadas en alta resolución (hasta 8160 x 6120 píxeles), lo que lo convierte en una herramienta eficaz para tareas de reconocimiento visual y recolección de datos para modelos de inteligencia artificial.

3.8. Desarrollo del trabajo de tesis

3.8.1. Recopilación de datos

Se llevó a cabo la recolección del conjunto de datos utilizando un dispositivo móvil personal ANDROID-SAMSUNG GALAXY S-23. Se capturaron 3,000 fotografías de diversas señalizaciones verticales basadas en el Manual de Dispositivos de Control del Tránsito Automotor (2024). Ubicadas en las principales vías de la ciudad de Ayacucho, que incluyen: Calle Nazareno, Jr. Carlos F. Vivanco, Jr. Libertad, Av. Mariscal Cáceres, Jr. Sol, Jr. Garcilaso de la Vega, Jr. Callao, Jr. Lima, Jr. San Martín, Jr. Tres Máscaras, Jr. 02 de Mayo, Jr. Cusco, Jr. Arequipa, Jr. Bellido, Jr. Grau, Av. Independencia, Av. 26 de Enero, Jr. Garcilazo de la Vega, Jr. Mario Ramos, Jr. Huanta, Av. Los Pinos, Jr. Asamblea, Jr. Sucre, Jr. Francisco Pizarro.

Las fotografías se capturaron en diversas condiciones de iluminación y clima, así como con enfoques cercanos y lejanos, para asegurar una mayor variabilidad en el conjunto de datos.



Figura 23: Condiciones soleadas (R-27A)
Fuente: Imagen propia



Figura 24: Condiciones soleadas (P-49)
Fuente: Imagen propia



Figura 25: Condiciones nocturnas (R-19)
Fuente: Imagen propia




Figura 26: Condiciones nocturnas (P-48)
Fuente: Imagen propia

3.8.2. Conjunto de datos de entrenamiento

De las 3,000 fotografías iniciales, se realizó una depuración para descartar aquellas que no cumplieran con los criterios de calidad. Se seleccionaron 2,250 imágenes en formato JPG

que fueron utilizadas para el entrenamiento del modelo. Estas imágenes cubren una amplia variedad de condiciones de luz y clima (diurnas y nocturnas). Esta diversidad es fundamental para asegurar la alta robustez del modelo, permitiéndolo un rendimiento eficaz incluso en situaciones complejas y evitando que dependa únicamente de condiciones ideales.



Nombre	Propietario	Última modificación	Tamaño de archivo
2216.jpg	yo	20 jun 2025 yo	57 KB
2215.jpg	yo	20 jun 2025 yo	66 KB
2214.jpg	yo	20 jun 2025 yo	60 KB
2213.jpg	yo	20 jun 2025 yo	58 KB
2212.jpg	yo	20 jun 2025 yo	58 KB
2204.jpg	yo	20 jun 2025 yo	71 KB
2199.jpg	yo	20 jun 2025 yo	71 KB
2197.jpg	yo	20 jun 2025 yo	71 KB
2191.jpg	yo	20 jun 2025 yo	75 KB
2184.jpg	yo	20 jun 2025 yo	75 KB
2183.jpg	yo	20 jun 2025 yo	75 KB
2179.jpg	yo	20 jun 2025 yo	120 KB
2178.jpg	yo	20 jun 2025 yo	120 KB
2167.jpg	yo	20 jun 2025 yo	124 KB
2157.jpg	yo	20 jun 2025 yo	127 KB
2154.jpg	yo	20 jun 2025 yo	127 KB
2153.jpg	yo	20 jun 2025 yo	126 KB

Figura 27: Conjunto de datos de entrenamiento en formato jpg
Fuente: Imagen propia

3.8.3. Etiquetado en LabelMe

El proceso de etiquetado de las señalizaciones verticales se implementó mediante una combinación de herramientas especializadas que garantizan precisión y eficiencia en la anotación de elementos. Como herramienta principal, se utilizó LabelMe, una plataforma de software de código abierto para la anotación de datos visuales en proyectos de visión por computadora y aprendizaje automático.

Para optimizar la precisión y velocidad del proceso de identificación y delimitación de las señalizaciones verticales, se integró Efficient SAM (Accuary), un modelo de segmentación que proporciona una precisión excepcional en la detección automática de señales de tráfico.

La interfaz intuitiva de LabelMe, potenciada por las capacidades de segmentación de Efficient SAM, facilita significativamente la delimitación precisa de las diferentes tipologías de señalizaciones verticales, incluyendo señales de tráfico reglamentarias, informativas y preventivas. Esta sinergia tecnológica reduce considerablemente el tiempo de anotación manual y minimiza errores en la clasificación de señalizaciones.

Esta metodología híbrida resulta especialmente valiosa para crear conjuntos de datos robustos destinados al entrenamiento de modelos de detección y reconocimiento automático de señalizaciones verticales, aplicaciones críticas en sistemas de conducción autónoma y asistencia al conductor. La adopción de esta metodología dual asegura un protocolo de etiquetado consistente y estandarizado para señalizaciones verticales, estableciendo las bases para un conjunto de datos de alta calidad que cumple con los estándares específicos de la investigación en sistemas de transporte inteligente y visión

por computadora aplicada al ámbito vial.

A.Definición de las categorías (clases)

Se define 14 categorías diferentes (clases) basadas en el Manual de Dispositivos de Control del Tránsito Automotor (2024). Estas incluyen señales reglamentarias, que establecen limitaciones, prohibiciones y restricciones específicas que los usuarios de la vía deben cumplir obligatoriamente (como límites de velocidad, zonas restringidas y señales de alto); señales informativas, que proporcionan orientación y datos útiles sobre destinos, distancias, servicios y características de la infraestructura vial para facilitar la navegación y toma de decisiones de los conductores; y señales preventivas, que alertan sobre condiciones peligrosas, cambios en las características de la vía o situaciones que requieren precaución especial por parte de los usuarios. Esta categorización sistemática permite una detección y clasificación automatizada más precisa mediante el modelo YOLO v8

Cuadro 2: Definición de categorías (clases)

Categoría (clase)	Clasificación de vehículos
NE	Señal de prohibido estacionar
SP	Señal preventiva zona de presencia de peatones
P	Señal informativa paradero de transporte público
NC	Señal prohibido ingreso de camiones
PP	Señal paradero prohibido
NCL	Señal prohibido el uso de la bocina
VM_20	Señal de velocidad máxima permitida: 20 km/h
PA	Señal reguladora de prioridad Pare
CV	Señal de control de velocidad
ZP	Señal informativa zona de parqueo autorizado
VM_30	Señal de velocidad máxima permitida: 30 km/h
RV	Señal proximidad reductor de velocidad tipo resalto
SB	Señal de prohibición vía segregada para buses
VR	Señal de prohibido circulación de vehículos automotores
CG	Señal prohibido la circulación de vehículos de carga

Fuente: Elaboración propia

1. Etiquetado de la categoría (clase)-Prohibido estacionar (NE) R-27 y R-27A




Figura 28: Etiquetado-NE-C.Soleada
Fuente: Imagen propia




Figura 29: Etiquetado-NE-C.Nocturna
Fuente: Imagen propia

2. Etiquetado de la categoría (clase)-Presencia de peatones (SP) P-48 y P-49




Figura 30: Etiquetado-SP-C.Soleada
Fuente: Imagen propia




Figura 31: Etiquetado-SP-C.Nocturna
Fuente: Imagen propia

3. Etiquetado de la categoría (clase)-Paradero de transporte público (P) I-23




Figura 32: Etiquetado-P-C.Soleada
Fuente: Imagen propia




Figura 33: Etiquetado-P-C.Nocturna
Fuente: Imagen propia

4. Etiquetado de la categoría (clase)-Prohibido ingreso de camiones (NC)-R-19




Figura 34: Etiquetado-NC-C.Soleada
Fuente: Imagen propia




Figura 35: Etiquetado-NC-C.Nocturna
Fuente: Imagen propia

5. Etiquetado de la categoría (clase)-Paradero Prohibido (PP)-R-44




Figura 36: Etiquetado-PP-C.Soleada
Fuente: Imagen propia




Figura 37: Etiquetado-PP-C.Nocturna
Fuente: Imagen propia

6. Etiquetado de la categoría (clase)-Prohibido usar bocina (NCL)-R-29




Figura 38: Etiquetado-NCL-C.Soleada
Fuente: Imagen propia




Figura 39: Etiquetado-NCL-C.Nocturna
Fuente: Imagen propia

7. Etiquetado de la categoría (clase)-Velocidad máxima permitida (VM_20), R-20




Figura 40: Etiquetado-VM_20-C.Soleada
Fuente: Imagen propia

Figura 41: Etiquetado-VM_20-C.Nocturna
Fuente: Imagen propia

8. Etiquetado de la categoría (clase)-Señal reguladora de prioridad-Pare (PA)




Figura 42: Etiquetado-PA-C.Soleada
Fuente: Imagen propia




Figura 43: Etiquetado-PA-C.Nocturna
Fuente: Imagen propia

9. Etiquetado de la categoría (clase)-Control de velocidad en autopista (I-3)




Figura 44: Etiquetado-Control de velocidad (CV)-Entorno soleado
Fuente: Imagen propia

10. Etiquetado de la categoría (clase)-Zona de parqueo autorizado (ZP)




Figura 45: Etiquetado-ZP-C.Soleada
Fuente: Imagen propia

Figura 46: Etiquetado-ZP-C.Nocturna
Fuente: Imagen propia

11. Etiquetado de la categoría (clase)-Velocidad máxima (VM_30)-R-30




Figura 47: Etiquetado-Velocidad máxima (VM_30)-Entorno nocturno
Fuente: Imagen propia

12. Etiquetado de la categoría (clase)-Proximidad de tipo resalto (RV)-P-33A




Figura 48: Etiquetado-RV-C.Soleada
Fuente: Imagen propia

Figura 49: Etiquetado-RV-C.Nocturna
Fuente: Imagen propia

13. Etiquetado de la categoría (clase)-Prohibición vía segregada para buses (SB)




Figura 50: Etiquetado-Solo Buses (SB)-Entorno soleado
Fuente: Imagen propia

14. Etiquetado de la categoría (clase)-Prohibido circulación de vehículos automotores (VR)-R-17




Figura 51: Etiquetado-Vehículo Restringido (VR)-Entorno soleado
Fuente: Imagen propia

B. Generación de los archivos con formato JSON

Posterior al proceso de etiquetado de imágenes, el sistema genera automáticamente un archivo de anotaciones en formato JSON correspondiente a cada imagen procesada, manteniendo el mismo nombre base del archivo original. Estos archivos de metadatos contienen la información estructurada y detallada de todas las etiquetas (bounding boxes) creadas para cada imagen específica, incluyendo las coordenadas de localización de los objetos detectados, las clases asignadas a cada señalización identificada. Esta información de anotaciones constituye el dataset fundamental que permite al algoritmo de aprendizaje automático reconocer y clasificar correctamente las 14 categorías de señalizaciones verticales definidas en el estudio.

3.8.4. Entrenamiento del modelo 104 épocas-GPU A-100

El entrenamiento del modelo de detección de señales verticales, compuesto por 14 clases, se llevó a cabo utilizando la arquitectura YOLOv8m (medium) sobre una GPU NVIDIA A100. Esta elección se basó en el equilibrio entre precisión y eficiencia computacional, proporcionando 25.9M parámetros que ofrecen una detección precisa sin incurrir en la sobrecarga computacional de modelos más grandes. Se aplicó la técnica de EarlyStopping con una paciencia de 20 épocas, permitiendo finalizar el entrenamiento automáticamente tras detectar falta de mejora en la métrica de validación, lo cual ocurrió en la época 104. El mejor desempeño se registró en la época 84, y el modelo óptimo fue guardado como best.pt. La infraestructura de la GPU A100, con alto rendimiento en operaciones de precisión mixta (FP16), facilitó una duración total de entrenamiento de apenas 0.793 horas, asegurando estabilidad numérica y una convergencia eficiente del modelo. El monitoreo continuo de las métricas de validación y el uso de estrategias de optimización durante el aprendizaje contribuyeron a un modelo robusto y generalizable.

1. Entrenamiento 104 épocas y análisis de gráficos

- **Histograma de instancias para las 14 clases de señalizaciones:** La distribución de instancias por clase muestra una base de datos balanceada, con la mayoría de las clases teniendo entre 130 y 150 ejemplos, lo cual favorece el desempeño del modelo al reducir el sesgo hacia clases mayoritarias. Las clases con mayor representación incluyen PA, ZP, NC y RV, todas por encima de las 145 instancias, lo que asegura un aprendizaje más robusto para dichas categorías y una mayor capacidad de generalización en escenarios reales. Esta densidad de datos permite al modelo identificar patrones visuales consistentes, lo cual resulta esencial para tareas de detección en condiciones variadas como iluminación cambiante, ángulos distintos o presencia de ruido visual.




Figura 52: Gráfico de barras-104 épocas
Fuente: Imagen propia generada en Python

Cuadro 3: Distribución de instancias por categoría de señalizaciones

Categoría/Clase	Número de instancias
NE (Prohibido Estacionar)	Aproximadamente 140
SP (Zona escolar)	Cerca de 140
P (Paradero de transporte público)	Aproximadamente 140
NC (Prohibido ingreso de camiones)	Aproximadamente 140
PP (Paradero Prohibido)	Cerca de 140
NCL (Prohibido usar bocina)	Menos de 140
VM_20 (Limite máximo de velocidad: 20 km/h)	Superior de 140
PA (Pare)	Superior de 140
CV (Control de velocidad)	Alrededor de 80
ZP (Zona de parqueo autorizado)	Alrededor de 140
VM_30 (Limite máximo de velocidad: 30 km/h)	Alrededor de 80
RV (Reductor de velocidad)	Superior de 140
SB (Solo Buses)	Alrededor de 140
VR (Vehículo restringido)	Superior de 80

Fuente: Elaboración propia.

- **Gráfico bounding box distribution plot:** Esta visualización muestra una alta concentración de cajas alineadas verticalmente en el centro, lo cual evidencia que las señales verticales fueron anotadas de forma consistente, con dimensiones similares y ubicaciones centradas en la imagen. Este comportamiento representa un dataset bien estructurado, especialmente cuando los objetos de interés (señales de tránsito verticales) son fotografiados en una vista frontal y a distancias similares. Las variaciones de color representan diferentes clases o imágenes individuales.




Figura 53: Gráfico bounding box distribution plot

Fuente: Imagen propia generada en Python

- **Gráfico bounding box centers:** Muestra la distribución espacial de las cajas delimitadoras muestra una alta densidad en la región central de las imágenes, con una concentración máxima alrededor de la coordenada (0.5, 0.5). Esto indica que las señales verticales fueron capturadas mayoritariamente centradas, lo cual facilita el aprendizaje del modelo y acelera la convergencia.




Figura 54: Gráfico bounding box centers
Fuente: Imagen propia generada en Python

- **Gráfico de dispersión 2D tipo heatmap:** El análisis de la distribución de tamaños de las cajas delimitadoras muestra una alta correlación entre ancho y alto, con una concentración principal en valores de altura entre 0.5 y 0.8, y de ancho entre 0.2 y 0.35. Esto confirma que la mayoría de las señales presentan una morfología vertical definida, lo cual facilita el aprendizaje de anchors eficientes y mejora la precisión del modelo. Esta regularidad estructural también contribuye a una mejor generalización, al reducir la complejidad de las formas que el modelo debe aprender. La presencia de algunas cajas fuera del patrón dominante sugiere variaciones puntuales que podrían analizarse más a fondo para asegurar consistencia en la anotación del dataset.




Figura 55: Gráfico de dispersión 2D tipo heatmap
Fuente: Imagen propia generada en Python

- **Gráfico scatter plot matrix:** Representa el análisis conjunto de las variables geométricas mediante un gráfico de pares revela una distribución estructurada y coherente de las cajas delimitadoras. Las coordenadas x y y muestran una alta concentración en el centro del espacio de la imagen, mientras que las dimensiones width y height evidencian una fuerte correlación, típica de objetos alargados verticalmente. La independencia relativa entre posición y tamaño favorece la capacidad del modelo para generalizar en la localización y detección.




Figura 56: Gráfico scatter plot matrix
Fuente: Imagen propia generada en Python

■ 1.2. Análisis gráfico: F1-Confidence Curve

La curva F1-Confidence evidencia una excelente calibración del modelo, alcanzando un valor F1 global de 1.00 en un umbral de confianza de 0.885. Este comportamiento indica un equilibrio óptimo entre precisión y exhaustividad en las predicciones. Las curvas individuales por clase se mantienen también muy cercanas a 1, reflejando un rendimiento consistente en todas las categorías del conjunto de señales verticales.




Figura 57: Gráfico:F1-Confidence Curve-104 épocas
Fuente: Imagen propia generada en Python

■ 1.3. Análisis gráfico: Precisión-Confidence curve

La curva Precision-Confidence revela que el modelo alcanza una precisión perfecta (1.00) a un umbral de confianza de 1.000, evidenciando la alta fiabilidad de las predicciones más seguras. A medida que se incrementa el umbral, la precisión mejora consistentemente en todas las clases, lo cual indica un bajo índice de falsos positivos. Este comportamiento refuerza la idoneidad del modelo para tareas donde es preferible reducir errores de clasificación, como en sistemas de asistencia a la conducción o entornos urbanos regulados. En combinación con la curva F1-Confidence, se concluye que el modelo ofrece tanto exactitud como equilibrio entre métricas clave.




Figura 58: Gráfico: Precisión-Confidence Curve-104 épocas

Fuente: Imagen propia generada en Python

■ 1.4. Análisis gráfico: Recall-Confidence Curve

La curva Recall-Confidence muestra que el modelo alcanza un valor máximo de recall de 1.00 al considerar todas las predicciones, incluso aquellas con confianza mínima (umbral = 0.000). Esto refleja la capacidad del modelo para detectar prácticamente todos los objetos reales del conjunto de validación. Sin embargo, a medida que se eleva el umbral de confianza, el recall disminuye, lo que indica la eliminación de verdaderos positivos en favor de predicciones más seguras. Este comportamiento es coherente con la dinámica clásica entre precisión y exhaustividad, y debe considerarse al seleccionar el umbral ideal de despliegue. Para aplicaciones sensibles donde es prioritario minimizar omisiones (como en seguridad vial), se recomienda un umbral más bajo que privilegie el recall, compensado con estrategias posteriores de validación o verificación.




Figura 59: Gráfico:Recall-Confidence Curve-104 épocas
Fuente: Imagen propia generada en Python

■ 1.5. Análisis gráfico: Precisión-Recall Curve

La curva Precision-Recall, junto con el valor de $mAP@0.5$, proporciona una visión integral del desempeño del modelo. El valor promedio alcanzado de 0.993 posiciona al modelo como altamente competente en la tarea de detección de señales verticales. Todas las clases, excepto una (CV con 0.973), superan los 0.99 en precisión media, lo que evidencia un equilibrio sobresaliente entre precisión y exhaustividad. Las curvas individuales se alinean en la zona óptima del gráfico, lo que respalda la consistencia del modelo en todas las categorías. Estos resultados validan no solo la calidad del modelo YOLOv8m utilizado, sino también la eficacia del dataset y del proceso de entrenamiento aplicando técnicas como EarlyStopping.




Figura 60: Gráfico:Precisión-Recall Curve-104 épocas
Fuente: Imagen propia generada en Python

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

Durante el entrenamiento del modelo YOLOv8m se observó una rápida y estable convergencia de las pérdidas asociadas a la detección (box, clasificación y DFL), con descensos pronunciados en las primeras épocas y una posterior estabilización en valores bajos. Las métricas de precisión y recall alcanzaron niveles cercanos al 100 % en las primeras 20 épocas, lo cual refleja una rápida asimilación de las características del conjunto de datos. De igual forma, el valor de $mAP@0.5$ se estabilizó en 0.993, y el $mAP@0.5-0.95$ superó el 0.98, confirmando la alta precisión espacial del modelo incluso en configuraciones más exigentes. No se observaron síntomas de sobreajuste gracias al uso de la técnica de EarlyStopping, y las métricas de validación mantuvieron un comportamiento paralelo al de entrenamiento durante todo el proceso.




Figura 61: Gráfico: Precisión-Recall Curve-104 épocas

Fuente: Imagen propia generada en Python

■ Métricas de entrenamiento del modelo

- **Early Stopping:** El proceso de entrenamiento se interrumpió automáticamente en la época 104, tras detectar ausencia de mejoras significativas en las últimas 20 iteraciones. Esta medida permite optimizar recursos computacionales y prevenir el sobreajuste, conservando la mejor versión del modelo.
- **Época óptima:** La mejor evaluación del modelo se alcanzó en la época 84, momento en el cual se almacenó el archivo best.pt, utilizado posteriormente para validación y tareas de inferencia.
- **Precisión media promedio ($mAP@0.5$): 0.993** Este valor demuestra un nivel de exactitud sobresaliente en la predicción de objetos con un umbral de superposición (IoU) del 50 %, superando ampliamente los estándares esperados para sistemas de visión artificial.
- **$mAP@0.5:0.95$: 0.992.** Este indicador refleja la capacidad del modelo para detectar objetos con diferentes niveles de solapamiento, lo que implica un rendimiento sólido incluso en condiciones de localización más exigentes.

- **Exactitud (Precisión): 0.997** El modelo acierta en casi todas las predicciones positivas realizadas, minimizando la cantidad de falsos positivos.
- **Cobertura (Recall): 0.997.** El sistema logra detectar prácticamente todos los objetos presentes en las imágenes, lo que evidencia su alta sensibilidad ante las distintas clases de señales.
- **Velocidad de preprocesamiento:** 0.3ms por imagen
- **Velocidad de inferencia:** 55.1 ms por imagen.
- **Velocidad de Postprocesamiento:** 0.9 ms por imagen.

Cuadro 4: Resultados mAP50 y mAP50-95, 104 épocas

Clases Específicas	Box (P)	Recall	mAP50	mAP50-95
Clase NE	0.999	1	0.995	0.995
Clase SP	0.998	1	0.995	0.995
Clase P	0.997	1	0.995	0.988
Clase NC	0.998	1	0.995	0.995
Clase PP	0.998	1	0.995	0.995
Clase NCL	0.998	1	0.995	0.994
Clase VM_20	0.998	1	0.995	0.995
Clase PA	0.997	1	0.995	0.992
Clase CV	0.996	0.957	0.973	0.973
Clase ZP	0.998	1	0.995	0.995
Clase VM_20	0.998	1	0.995	0.995
Clase RV	0.997	1	0.995	0.995
Clase SB	0.998	1	0.995	0.993
Clase VR	0.995	1	0.995	0.995

Fuente: Elaboración propia.

Cuadro 5: Tiempos de Procesamiento-104 épocas-YOLOv8S, GPU A100 de 40 GB.

Tiempos	Velocidad
Preprocesamiento	0.3 ms (validación) / 0.1 ms (evaluación)
Inferencia	55.1 ms (validación) / 31.5 ms (evaluación)
Postprocesamiento	0.9 ms (validación) / 1.1 ms (evaluación)

Fuente: Elaboración propia.

3.8.5. Determinación y análisis de las zonas de simulación de viajes

Se realizaron simulaciones de viajes vehiculares en las vías principales de la ciudad de Ayacucho, replicando las condiciones reales de desplazamiento de un vehículo en movimiento bajo diversas velocidades operacionales. Esta metodología permite evaluar la efectividad del sistema de inteligencia artificial en condiciones dinámicas similares a las experimentadas por los conductores en situaciones reales de tránsito, con el objetivo de validar la capacidad del modelo de visión artificial para detectar y clasificar señalizaciones de tránsito en tiempo real, bajo diferentes velocidades de desplazamiento y condiciones de tráfico, simulando la perspectiva y experiencia de un conductor real en las vías de Ayacucho.

La implementación de simulaciones vehiculares permite evaluar el sistema de inteligencia artificial bajo condiciones que replican fielmente la experiencia del conductor urbano. A diferencia de las pruebas estáticas tradicionales, este enfoque dinámico considera variables críticas como la velocidad de aproximación a las señales, el tiempo de exposición visual, la distancia de detección efectiva y los factores ambientales cambiantes que influyen en la percepción de la señalización vial.

Las simulaciones se desarrollaron considerando las características particulares del entorno vial ayacuchano, el cual presenta desafíos específicos que incrementan la complejidad de la detección automatizada de señalizaciones. El sistema de inteligencia artificial fue sometido a pruebas en un contexto urbano caracterizado por:

- **Calles estrechas de morfología colonial:** Las vías de Ayacucho, especialmente en el centro histórico, mantienen la traza urbana colonial con anchos de calzada reducidos, que genera limitaciones en los ángulos de visión y reduce las distancias de detección anticipada disponibles para los sistemas automatizados.
- **Topografía irregular con pendientes pronunciadas:** La ubicación de la ciudad en terreno montañoso (2,761 msnm) genera pendientes que varían entre 8 % y 15 % en diversas calles, afectando tanto la velocidad de desplazamiento vehicular como los ángulos de incidencia visual sobre las señalizaciones.
- **Incumplimiento de normativas técnicas:** Durante las simulaciones se evidenció que gran parte de la señalización instalada no cumple con las especificaciones del Manual de Dispositivos de Control del Tránsito Automotor, presentando ubicaciones inadecuadas, alturas incorrectas, y orientaciones que no optimizan su visibilidad.
- **Deterioro avanzado de señalizaciones:** Se identificó un porcentaje significativo de señales con desgaste avanzado, decoloración, oxidación y daños físicos que comprometen su legibilidad.

Las simulaciones se realizaron en un contexto donde se observa un desacato sistemático a la señalización existente por parte de conductores y peatones, lo que paradójicamente incrementa la importancia de contar con sistemas de detección automatizada que puedan alertar sobre señalizaciones que frecuentemente son ignoradas. Esta problemática contextual convierte a las vías de Ayacucho en un laboratorio natural ideal para validar la robustez de sistema en condiciones adversas. A continuación se definen 05 viajes que se realizó:

Características-viaje 01-Condición mañana- tarde

El Viaje 01 comprende un circuito integral que abarca las principales arterias del centro histórico de Ayacucho, iniciando desde el Parque Magdalena (sector nor-este) y descendiendo por la vía paralela de la Plaza Mayor de Huamanga (corazón del centro histórico), para posteriormente continuar hacia el Arco del Triunfo (sector sur-este) y luego volver al parque Magdalena.

- **Jr. Tres Máscaras:** Vía de acceso norte al centro histórico.
- **Jr. Carlos F. Vivanco:** Arteria principal comercial-patrimonial.
- **Jr. Mario Ramos:** Conector hacia zona comercial central.
- **Jr. Francisco Pizarro:** Eje histórico hacia Plaza Mayor.
- **Jr. Huanta:** Continuación hacia sector residencial-comercial.
- **Av. Mariscal Cáceres:** Arteria principal de salida del centro.



Figura 62: Circuito integral viaje 01
Fuente: Imagen propia

Características-viaje 02-condición mañana-tarde

El Viaje 02 constituye un circuito ampliado que abarca tanto el núcleo histórico como la zona de expansión comercial-residencial de Ayacucho. El recorrido forma un gran anillo perimetral que inicia en la Av. Mariscal Cáceres (sector nor-este), atravesando Jr.Libertad, para posteriormente descender por Calle Nazareno y Jr.Carlos F.Vivanco, cursando por el Arco del Triunfo antes de retornar al punto de origen.

- **Av. Mariscal Cáceres:** Arteria principal comercial de alto flujo.
- **Jr. Libertad:** Eje comercial-residencial consolidado.
- **Calle Nazareno:** Conector hacia zona residencial sur-este.
- **Jr. Carlos F. Vivanco:** Arteria histórico-comercial principal.
- **Jr. Mario Ramos:** Transición comercial-residencial.
- **Jr. San Martín:** Eje residencial-institucional.
- **Jr. 02 de Mayo:** Corredor hacia zona del centro histórico.
- **Jr. Arequipa:** Conector residencial.



Figura 63: Circuito integral viaje 02
Fuente: Imagen propia

Características-viaje 03-condición mañana-tarde

El Viaje 03 constituye un circuito de arterias principales que abarca las vías de mayor capacidad vehicular y jerarquía vial de Ayacucho. El recorrido forma un anillo arterial que conecta los principales nodos urbanos, iniciando desde Grifo Gomebool (sector nor-este), transitando por la Urbanización Mariscal Andrés Avelino Cáceres, y descendiendo por la vía de Av. 26 de enero antes de retornar al origen.

- **Av. Mariscal Cáceres:** Arteria principal de mayor jerarquía urbana.

- **Jr. Garcilazo de la Vega:** Eje histórico-comercial secundario.
- **Av. 26 de Enero:** Arteria comercial-institucional.
- **Av. Los Pinos:** Corredor residencial consolidado.
- **Av. Independencia:** Eje comercial-administrativo principal.
- **Jr. Asamblea:** Conector hacia zona comercial popular.



Figura 64: Circuito integral viaje 03
Fuente: Imagen propia

Características-viaje 04-condición nocturna

El Viaje 04 constituye un corredor institucional-deportivo que conecta la zona de desarrollo urbano planificado con el núcleo comercial-administrativo de Ayacucho. El recorrido presenta una configuración lineal descendente que inicia en la Urbanización Mariscal Andrés Avelino Cáceres (zona alta residencial-institucional) y desciende hacia el centro urbano, atravesando diferentes gradientes funcionales y morfológicos.

- **Av. 26 de Enero:** Arteria administrativa-comercial central.
- **Av. Independencia:** Eje institucional-educativo principal.
- **Jr. Asamblea:** Conector hacia zona comercial popular
- **Av. Mariscal Cáceres:** Arteria principal de retorno.
- **Jr. Libertad:** Eje comercial-residencial de cierre.



Figura 65: Circuito integral viaje 04
Fuente: Imagen propia

Características-viaje 05-condición nocturna

El Viaje 05 constituye el circuito integral más exhaustivo de toda la investigación, representando una síntesis completa de todos los contextos urbanos, tipos de vías y condiciones operacionales presentes en la ciudad de Ayacucho. Este recorrido forma un gran circuito metropolitano que abarca prácticamente toda la zona urbana consolidada, integrando elementos de los cuatro viajes anteriores.




Figura 66: Circuito integral viaje 05
Fuente: Imagen propia

3.8.6. Desarrollo y arquitectura del sistema

Se diseñó un modelo de optimización multicapa que toma como base un modelo YOLOv8 pre-entrenado (best_seguridad.pt) para detección de señales verticales de tránsito y le añade sistemas de optimización complementarios que transforman las detecciones básicas en un sistema inteligente de seguridad vial. La metodología empleada se estructuró en fases secuenciales: Análisis de requerimientos técnicos, diseño de la arquitectura del sistema, implementación de componentes individuales, integración progresiva de módulos, y finalmente, pruebas de validación y optimización del rendimiento.

Capacidades principales del modelo optimizado:

1. Arquitectura del sistema y tecnologías principales

- **Arquitectura del sistema:** La arquitectura del software se fundamentó en la clase principal "Modelo Visión Artificial Ayacucho" que actúa como controlador central y coordina sistemas especializados independientes.
- **Tecnologías principales:** Se seleccionó Python como lenguaje principal, se justifica por su extenso ecosistema para inteligencia artificial y visión computacional, así como por la disponibilidad de bibliotecas especializadas como OpenCV, NumPy y Ultralytics YOLO. Esta decisión se respaldó en la necesidad de integrar múltiples tecnologías de manera eficiente y mantener la legibilidad del código para futuras extensiones de la investigación.
- **Bibliotecas especializadas:** Se integraron bibliotecas especializadas para optimización de rendimiento: Numba para aceleración JIT de cálculos matemáticos críticos, psutil para monitoreo de recursos del sistema, y SQLite para persistencia de datos.




Figura 67: Intefaz gráfica al iniciar el software
Fuente: Imagen propia

2. Capacidad de persistencia temporal

- **Memoria temporal:** El modelo extiende YOLOv8 con un sistema de memoria temporal que mantiene un registro histórico de detecciones a través de múltiples frames, asigna identificadores únicos a cada señal detectada para seguimiento individual, e implementa algoritmos de asociación espacial para vincular detecciones del mismo objeto. Los modelos YOLO tradicionales procesan cada frame de manera independiente. Esto causa que una señal de tránsito aparezca y desaparezca constantemente en el video (efecto parpadeo), incluso cuando la señal está siempre visible. Tu sistema soluciona este problema fundamental manteniendo una "memoria" de las detecciones anteriores.
- **Funcionamiento de detecciones a través del tiempo, asignando IDs únicos y rastreando posiciones:** En lugar de tratar cada detección particularmente, el sistema asigna un ID único a cada nueva señal detectada, de esa manera rastrea la posición de esa señal en frames posteriores, mantiene un historial temporal de dónde ha estado esa señal, asocia detecciones nuevas con señales ya conocidas si están cerca espacialmente.
- **Tolerancia espacial (70 píxeles) para asociar detecciones nuevas con existentes:** En lugar de tratar cada detección particularmente, el sistema asigna un ID único a cada nueva señal detectada, de esa manera rastrea la posición de esa señal en frames posteriores, mantiene un historial temporal de dónde ha estado esa señal, asocia detecciones nuevas con señales ya conocidas si están cerca espacialmente.



Figura 68: Selección del nivel de confianza-consola del sistema
Fuente: Imagen propia

3. Controlador de velocidad avanzado

- **AdvancedSpeedController:** El modelo incorpora optimizaciones computacionales avanzadas con compilación JIT Numba, sistema de velocidad adaptativo con 8 configuraciones predefinidas y gestión inteligente de memoria. El sistema permite procesar videos a 8 velocidades diferentes, cada una

optimizada para un propósito específico. 0.5x-1.0x: para análisis muy detallado, investigación, validación minuciosa, 2.0x-4.0x: Análisis acelerado, manteniendo precisión, 6.0x-8.0x: Procesamiento rápido para grandes volúmenes de video, simulando velocidades de viajes altos, 8.0x-10.0x-MAX, ultra velocidad para reconocimiento rápido de patrones. El sistema de velocidad adaptativa implementado en `get_optimal_delay()` ajusta dinámicamente estos parámetros según el uso de CPU, aplicando multiplicadores específicos: Duplicación del delay cuando el uso supera 90 %, multiplicación por 1.5 entre 80-90 %, y reducción a la mitad cuando es menor al 30 %.



Figura 69: Velocidad 1.0x-Normal balanceada
Fuente: Imagen propia



Figura 70: Velocidad 20.0x-Máxima velocidad
Fuente: Imagen propia

4. Sistema de alertas de voz optimizado

- El modelo añade inteligencia contextual a las detecciones de YOLOv8 con sistema de clasificación semántica, priorización de alertas y generación de mensajes específicos. En lugar de mensajes genéricos como "señal

detectada”, el sistema tiene mensajes específicos y útiles para cada tipo de señal. Se implementó un mecanismo de control temporal mediante el diccionario `last_alert_time`, aplicando cooldowns específicos de 6 segundos para mensajes regulares y periodos extendidos para alertas críticas. El sistema incorpora múltiples métodos de síntesis de voz para garantizar compatibilidad multiplataforma: `pyttsx3` como método primario, PowerShell para sistemas Windows. Se desarrolló específicamente el método `speak_immediate_sync()` para mensajes críticos que requieren reproducción inmediata y síncrona, especialmente importante para alertas de seguridad vial.



Figura 71: Sistema de alerta de voz optimizado por clases
Fuente: Imagen propia

Cuadro 6: Sistema de alerta de voz optimizado por clases

Categoría/Clase	Contextualización semántica
NE (Prohibido Estacionar)	Cuidado - Zona de no estacionarse - está prohibido aparcar aquí
SP (Zona escolar)	Zona escolar detectada- Extreme precauciones por presencia de niños
P (Paradero de transporte público)	Paradora autorizado - Zona de parada para transporte público
NC (Prohibido ingreso de camiones)	Prohibido circulación de camiones - solo vehículos livianos

Continúa en la siguiente hoja

Cuadro 6: Sistema de alerta de voz optimizado por clases (Continued)

Categoría/Clase	Contextualización semántica
PP (Paradero Prohibido)	Alerta - Paradero Prohibido - No puede estacionarse en esta zona
NCL (Prohibido usar bocina)	Zona de silencio - Prohibido el uso de claxon o bocina
VM_20 (Limite máximo de velocidad: 20 km/h)	Reduzca su velocidad a veinte kilómetros por hora inmediatamente
PA (Pare)	Atención conductor - señal de pare detectada - detenga su vehículo completamente
CV (Control de velocidad)	Zona de control de velocidad - mantenga límites establecidos
ZP (Zona de parqueo autorizado)	Zona de parqueo autorizada - Puede estacionarse aquí
VM_30 (Limite máximo de velocidad: 30 km/h)	Límite de velocidad- Máximo treinta kilómetros por hora
RV (Reductor de velocidad)	Precaución - Reductor de velocidad adelante - Disminuye la velocidad
SB (Solo Buses)	Carril exclusivo para buses - Solo transporte público autorizado
VR (Vehículo restringido)	Vehículo restringido - Verifique si está autorizado para circular

Fuente: Elaboración propia.

5. Capacidad de registro y análisis inteligente

El modelo implementa sistema de documentación inteligente con base de datos relacional SQLite, sistema de señales únicas con deduplicación espacial

y exportación automática de reportes. El sistema distingue entre detecciones múltiples de la misma señal física versus señales diferentes. Si detecta por ejemplo una señal de PARE en la coordenada (100,200) múltiples veces, entiende que es la misma señal física, no varias señales diferentes. Todos los datos se guardan permanentemente en una base de datos profesional que incluye timestamp de cada detección, coordenadas exactas, nivel de confianza, duración de la detección, el sistema presenta una mejora progresiva, actualiza confianza cuando detecta la misma señal múltiples veces. Si una señal es detectada repetidamente con alta confianza, el sistema aumenta su certeza sobre esa señal. Esto mejora la precisión del análisis estadístico final.

- **Descripción técnica:** El modelo proporciona control en tiempo real sin interrumpir el procesamiento, con configuración dinámica, visualización multicapa y monitoreo de sistema en vivo. No se necesita detener el análisis para cambiar configuraciones. Mientras el video se procesa, se puede ajustar velocidad, confianza, persistencia, grosor de líneas, etc., y los cambios se aplican inmediatamente.
- **Visualización dual: Video procesado + consola de detecciones persistentes+consola del sistema:** La interfaz muestra dos áreas principales, el video con las detecciones visualizadas en tiempo real, y una consola de texto que muestra el historial de detecciones persistentes y consola del sistema, con timestamps y detalles.




Figura 72: Video procesado + consola de detecciones persistentes+consola del sistema:
Fuente: Imagen propia

6. Implementaciones específicas del modelo

- Para realizar la implementación efectiva del modelo de visión artificial desarrollado, se ejecutó un proceso sistemático de recolección de datos visuales mediante la grabación de videos que representan trayectos reales por las vías principales de Huamanga. Esta metodología de captura de datos se diseñó específicamente para garantizar la representatividad y diversidad necesaria.

4. RESULTADOS

4.1. Contrastación de hipótesis

4.1.1. Contrastación de hipótesis específica 1

- La arquitectura del modelo, basado en redes neuronales convolucionales (CNN), permite la detección, clasificación de 14 señalizaciones verticales basado en el Manual de dispositivos de control del tránsito automotor.

Se diseñó una arquitectura basada en YOLO (You Only Look Once) específicamente ajustada para la detección de 14 señalizaciones verticales basado en el Manual de dispositivos de control del tránsito automotor. La implementación de esta arquitectura no solo valida la hipótesis planteada, sino que también demuestra la viabilidad técnica de utilizar inteligencia artificial para mejorar la señalización y seguridad vial mediante soluciones automatizadas, eficientes y en tiempo real.

A continuación, se detallan los resultados de las detecciones realizadas, categorizadas según el Manual de Dispositivos de Control del Tránsito Automotor.

Cuadro 7: Señalizaciones verticales detectadas por el modelo

Categoría (clase)	Clasificación de vehículos
PA	Señal reguladora de prioridad Pare
NC	Señal prohibido ingreso de camiones
VR	Señal de prohibido circulación de vehículos automotores
SB	Señal de prohibición vía segregada para buses
NE	Señal de prohibido estacionar
NCL	Señal prohibido el uso de la bocina
PP	Señal paradero prohibido
SP	Señal preventiva zona de presencia de peatones
P	Señal informativa paradero de transporte público
VM_20	Señal de velocidad máxima permitida: 20 km/h
VM_30	Señal de velocidad máxima permitida: 30 km/h
RV	Señal proximidad reductor de velocidad tipo resalto
CV	Señal de control de velocidad
ZP	Señal informativa zona de parqueo autorizado
CG	Señal prohibido la circulación de vehículos de carga

Fuente: Elaboración propia

1. Señal reguladora o de reglamentación.

1.1 Señal de prioridad:



Figura 73: Señal de prioridad (R-1)-PARE-clase PA
Fuente: Imagen propia

1.2 Señal de prohibición de paso por clase de vehículo:



Figura 74: Señal de prohibición (R-19)-Prohibido circulación de vehículos de carga-clase NC)
Fuente: Imagen propia



Figura 75: Señal prohibición (R-17)-Prohibido circulación vehículos automotores-clase VR)
Fuente: Imagen propia



Figura 76: Señal vía segregada para buses (R-55A,R-55B,-clase SB))
Fuente: Imagen propia

1.3 Señales de prohibición adicionales:




Figura 77: Señal prohibido estacionar zona de remolque (R-27A)-clase NE)
Fuente: Imagen propia



Figura 78: Señal prohibido el uso de la bocina (R-29)-clase NCL
Fuente: Imagen propia



Figura 79: Señal paradero prohibido (R-44)-clase PP
Fuente: Imagen propia

1.4 Señales de restricción.



Figura 80: Señal velocidad máxima permitida (R-20)- VM_20
Fuente: Imagen propia




Figura 81: Señal velocidad máxima permitida (R-30)- VM_30
Fuente: Imagen propia

2. Señales de prevención.

2.1 Señales preventivas por características de la superficie de rodadura:



Figura 82: Señal proximidad reductor de velocidad tipo resalto (P-33A)-Clase RV
Fuente: Imagen propia

2.2 Señales preventivas por características operativas de la vía:



Figura 83: Señal zona de presencia de peatones (P-48)
Fuente: Imagen propia



Figura 84: Señal zona escolar (P-49)
Fuente: Imagen propia

3. Señal de control de velocidad en autopista:



Figura 85: Señal de control de velocidad en autopista (I-3)-Clase CV
Fuente: Imagen propia

4. Señal informativa sobre tarifas y condiciones de parqueo en zona autorizada:

Figura 86: Señal informativa sobre tarifas en zona de parqueo
Fuente: Imagen propia


5. Señal informativa-Paradero de transporte publico:

Figura 87: Señal informativa: I-23 Paradero de transporte público-Clase P
Fuente: Imagen propia

Resultados de detección de señalizaciones en condiciones adversas.**1. Detección de señalizaciones verticales pandeadas:**

Figura 88: Detección de señalizaciones pandeadas
Fuente: Imagen propia


2. Detección de señalizaciones verticales parcial/completamente ocluidas:

Figura 89: Detección de señalizaciones parcialmente ocluidas
Fuente: Imagen propia



Figura 90: Detección de señalizaciones ocluidas por arbustos
Fuente: Imagen propia

3. Detección de señalizaciones verticales visiblemente desgastadas:




Figura 91: Detección de señalizaciones, visiblemente desgastadas
Fuente: Imagen propia




Figura 92: Detección de señalizaciones, visiblemente desgastadas y ocluidas
Fuente: Imagen propia

4. Detección de señalizaciones verticales múltiples:



Figura 93: Detección múltiple de señalizaciones
Fuente: Imagen propia

4.1.2. Contrastación de hipótesis específica 2

- El entrenamiento del modelo, basado en redes neuronales convolucionales (CNN) logra una mayor precisión de clase, recall y velocidades de inferencia ultrarrápidas, evitando el sobreajuste.

La segunda hipótesis de este estudio fue evaluar el rendimiento del modelo basado en Redes Neuronales Convolucionales (CNN), con el fin de verificar su capacidad para lograr una mayor precisión de clase, recall y velocidades de inferencia ultrarrápidas. El entrenamiento del modelo de detección de señales verticales, compuesto por 14 clases, se llevó a cabo utilizando la arquitectura YOLOv8m (medium) sobre una GPU NVIDIA A100. Esta elección se basó en el equilibrio entre precisión y eficiencia computacional. Se aplicó la técnica de EarlyStopping para evitar el sobreajuste con una paciencia de 20 épocas, permitiendo finalizar el entrenamiento automáticamente tras detectar falta de mejora en la métrica de validación, lo cual ocurrió en la época 104. El mejor desempeño se registró en la época 84, y el modelo óptimo fue guardado como best_seguridad.pt.

Evaluación del entrenamiento del modelo basado en CNN

- **Early Stopping:** El proceso de entrenamiento se interrumpió automáticamente en la época 104, tras detectar ausencia de mejoras significativas en las últimas 20 iteraciones. Esta medida permite optimizar recursos computacionales y prevenir el sobreajuste, conservando la mejor versión del modelo.
- **Época óptima:** La mejor evaluación del modelo se alcanzó en la época 84, momento en el cual se almacenó el archivo best.pt, utilizado posteriormente para validación y tareas de inferencia.
- **Precisión media promedio (mAP@0.5): 0.993.** Este valor demuestra un nivel de exactitud sobresaliente en la predicción de objetos con un umbral de superposición (IoU) del 50 %, superando ampliamente los estándares esperados para sistemas de visión artificial.
- **mAP@0.5:0.95: 0.992.** Este indicador refleja la capacidad del modelo para detectar objetos con diferentes niveles de solapamiento, lo que implica un rendimiento sólido incluso en condiciones de localización más exigentes.
- **Exactitud (Precisión): 0.997.** El modelo acierta en casi todas las predicciones positivas realizadas, minimizando la cantidad de falsos positivos.
- **Cobertura (Recall): 0.997.** El sistema logra detectar prácticamente todos los objetos presentes en las imágenes, lo que evidencia su alta sensibilidad ante las distintas clases de señales.
- **Velocidad de preprocesamiento:** 0.3 ms por imagen.
- **Velocidad de inferencia:** 55.1 ms por imagen.
- **Velocidad de postprocesamiento:** 0.9 ms por imagen.

Cuadro 8: Resultados mAP50 y mAP50-95, 104 épocas

Clases Específicas	Box (P)	Recall	mAP50	mAP50-95
Clase NE	0.999	1.000	0.995	0.995
Clase SP	0.998	1.000	0.995	0.995
Clase P	0.997	1.000	0.995	0.988
Clase NC	0.998	1.000	0.995	0.995
Clase PP	0.998	1.000	0.995	0.995
Clase NCL	0.998	1.000	0.995	0.994
Clase VM_20	0.998	1.000	0.995	0.995
Clase PA	0.997	1.000	0.995	0.992
Clase CV	0.996	0.957	0.973	0.973
Clase ZP	0.998	1.000	0.995	0.995
Clase VM_30	0.998	1.000	0.995	0.995
Clase RV	0.997	1.000	0.995	0.995
Clase SB	0.998	1.000	0.995	0.993
Clase VR	0.995	1.000	0.995	0.995

Fuente: Elaboración propia.

Cuadro 9: Tiempos de Procesamiento - 104 épocas - YOLOv8, GPU A100 de 40 GB

Tiempos	Velocidad
Preprocesamiento	0.3 ms (validación) / 0.1 ms (evaluación)
Inferencia	55.1 ms (validación) / 31.5 ms (evaluación)
Postprocesamiento	0.9 ms (validación) / 1.1 ms (evaluación)

Fuente: Elaboración propia.

Los cuadros de resultados reflejan un alto desempeño del modelo de detección basado en YOLOv8 tras 104 épocas de entrenamiento, evidenciado por métricas sobresalientes donde la mayoría de las clases específicas alcanzan un valor de precisión y recall igual o cercano a 1.000, lo que indica una capacidad casi perfecta del modelo para identificar correctamente las señales de tránsito sin generar falsos negativos. Destaca la clase CV (Señal de control de velocidad), que presenta un ligero descenso en el recall (0.957) y en mAP50 y mAP50-95 (0.973), aunque sigue siendo un rendimiento alto. En cuanto a los tiempos de procesamiento, el modelo demuestra eficiencia computacional, con una velocidad promedio de 0.3 ms en preprocesamiento, 55.1 ms en inferencia y 0.9 ms en postprocesamiento durante la validación, y tiempos aún menores durante la evaluación. Estos resultados confirman

que el modelo no solo es preciso, sino también lo suficientemente rápido como para ser viable en aplicaciones en tiempo real orientadas a la seguridad vial. A continuación, se detallan los gráficos de desempeño obtenidos tras el entrenamiento y validación del modelo.

Gráficos de métricas de entrenamiento y validación del modelo - 104 épocas

- **Gráfico bounding box distribution plot:**




Figura 94: Gráfico bounding box distribution plot
Fuente: Imagen propia generada en Python

- **Gráfico bounding box centers:**




Figura 95: Gráfico bounding box centers
Fuente: Imagen propia generada en Python

- **Gráfico de dispersión 2D tipo heatmap:**




Figura 96: Gráfico de dispersión 2D tipo heatmap
Fuente: Imagen propia generada en Python

- **Gráfico scatter plot matrix:**




Figura 97: Gráfico scatter plot matrix
Fuente: Imagen propia generada en Python

- **Gráfico F1-Confidence curve:**




Figura 98: Gráfico: F1-Confidence Curve - 104 épocas
Fuente: Imagen propia generada en Python

- **Gráfico Precisión-Confidence curve:**




Figura 99: Gráfico: Precisión-Confidence Curve - 104 épocas
Fuente: Imagen propia generada en Python

• **Gráfico Recall-Confidence Curve:**




Figura 100: Gráfico: Recall-Confidence Curve - 104 épocas
Fuente: Imagen propia generada en Python

• **Gráfico Precisión-Recall Curve:**




Figura 101: Gráfico: Precisión-Recall Curve - 104 épocas
Fuente: Imagen propia generada en Python

• **Gráfico panel de métricas de entrenamiento y validación:**




Figura 102: Panel de métricas de entrenamiento y validación - 104 épocas
Fuente: Imagen propia generada en Python

4.1.3. Contrastación de hipótesis específica 3

- La implementación del modelo, basado en redes neuronales convolucionales (CNN) permite el desarrollo de un software para la detección automatizada de señalizaciones verticales, integrando un sistema de alertas por voz optimizado que garantice una reproducción inmediata y sincrónica, fundamental para la emisión oportuna de advertencias en materia de seguridad vial.

Se desarrolló un software especializado, sustentado en una arquitectura de redes neuronales convolucionales (CNN), para la detección automatizada de señalizaciones verticales en vías urbanas. Esta herramienta integra un sistema de alertas por voz optimizado que permite emitir advertencias de manera inmediata y sincrónica. El objetivo es garantizar una respuesta eficiente en tiempo real frente a señales de tránsito relevantes, fortaleciendo así la capacidad preventiva de los conductores y promoviendo una conducción más segura. La integración del sistema de audio permite no solo identificar visualmente las señales, sino también generar mensajes auditivos claros y oportunos que advierten sobre restricciones, precauciones o informaciones críticas presentes en la vía. Esta implementación contribuye directamente a la mejora de la seguridad vial, al reducir el tiempo de reacción del conductor ante situaciones que demandan atención o maniobras específicas, especialmente en contextos de tráfico denso o condiciones ambientales adversas.

Se realizaron simulaciones de viajes vehiculares en las vías principales de la ciudad de Ayacucho, replicando las condiciones reales de desplazamiento de un vehículo en movimiento bajo diversas velocidades operacionales. Esta metodología permite evaluar la efectividad del sistema de inteligencia artificial en condiciones dinámicas similares a las experimentadas por los conductores en situaciones reales de tránsito, con el objetivo de validar la capacidad del modelo de visión artificial para detectar y clasificar señalizaciones de tránsito en tiempo real, bajo diferentes velocidades de desplazamiento y condiciones de tráfico, simulando la perspectiva y experiencia de un conductor real en las vías de Ayacucho.



Figura 103: Metodología de captura de viajes
Fuente: Imagen propia



Figura 104: Simulación de viajes en vehículos autonomos
Fuente: Imagen propia

La implementación de simulaciones vehiculares permite evaluar el sistema de inteligencia artificial bajo condiciones que replican fielmente la experiencia del conductor urbano. A diferencia de las pruebas estáticas tradicionales, este enfoque dinámico considera variables críticas como la velocidad de aproximación a las señales, el tiempo de exposición visual, la distancia de detección efectiva y los factores ambientales cambiantes que influyen en la percepción de la señalización vial.

Las simulaciones se desarrollaron considerando las características particulares del entorno vial ayacuchano, el cual presenta desafíos específicos que incrementan la complejidad de la detección automatizada de señalizaciones. El sistema de inteligencia artificial fue sometido a pruebas en un contexto urbano caracterizado por:

- **Calles estrechas de morfología colonial:** Las vías de Ayacucho, especialmente en el centro histórico, mantienen la traza urbana colonial con anchos de calzada reducidos, que genera limitaciones en los ángulos de visión y reduce las distancias de detección anticipada disponibles para los sistemas automatizados.
- **Topografía irregular con pendientes pronunciadas:** La ubicación de la ciudad en terreno montañoso (2,761 msnm) genera pendientes que varían entre 8 % y 15 % en diversas calles, afectando tanto la velocidad de desplazamiento vehicular como los ángulos de incidencia visual sobre las señalizaciones.
- **Incumplimiento de normativas técnicas:** Durante las simulaciones se evidenció que gran parte de la señalización instalada no cumple con las especificaciones del Manual de Dispositivos de Control del Tránsito Automotor, presentando ubicaciones inadecuadas, alturas incorrectas, y orientaciones que no optimizan

su visibilidad.

- **Deterioro avanzado de señalizaciones:** Se identificó un porcentaje significativo de señales con desgaste avanzado, decoloración, oxidación y daños físicos que comprometen su legibilidad, representando un desafío adicional para la robustez del algoritmo de reconocimiento.

Resultados del viaje 01-Integrando el sistema de aleta de voz

d01.0d0

Figura 105: Circuito integral viaje 01
Fuente: Imagen propia




Figura 106: Detección-Clase NE-0.60
Fuente: Imagen propia



Figura 107: Detección-Clase NE-0.85
Fuente: Imagen propia







Figura 111: Detección-Clase RV-0.81
Fuente: Imagen propia



Figura 112: Detección-Clase SP-0.81
Fuente: Imagen propia




Figura 113: Detección-Clase NE-0.81
Fuente: Imagen propia



Figura 114: Detección-Clase SP-0.87
Fuente: Imagen propia




Figura 115: Detección-Clase NC-0.60
Fuente: Imagen propia




Figura 116: Detección-Clase NE-0.90
Fuente: Imagen propia








Figura 122: Detección-Clase VM_20-0.90
Fuente: Imagen propia




Figura 123: Detección-Clase P-0.59
Fuente: Imagen propia




Figura 124: Detección-Clase ZP-0.63
Fuente: Imagen propia



Figura 125: Detección-Clase VR-0.88
Fuente: Imagen propia



Figura 126: Detección-Clase NE-0.82
Fuente: Imagen propia



Figura 127: Detección-Clase NE-0.82-Estable
Fuente: Imagen propia

Resultados del viaje 03-Integrando el sistema de alerta de voz



Figura 128: Circuito integral viaje 03
Fuente: Imagen propia



Figura 129: Detección-Clase RV-0.65
Fuente: Imagen propia



Figura 130: Detección-Clase NE-0.91
 Fuente: Imagen propia



Figura 131: Detección-Clase NE-0.92
 Fuente: Imagen propia




Figura 132: Detección-Clase NE-0.83
 Fuente: Imagen propia



Figura 133: Detección-Clase SP-0.75
Fuente: Imagen propia



Figura 134: Detección-Clase SP-0.88
Fuente: Imagen propia




Figura 135: Detección-Clase P-0.90
Fuente: Imagen propia

Resultados del viaje 04-Integrando el sistema de alerta de voz



Figura 136: Circuito integral viaje 04
Fuente: Imagen propia






Figura 138: Detección nocturna-Clase NE-0.86
Fuente: Imagen propia



Figura 139: Detección nocturna-Clase NE-0.85
Fuente: Imagen propia

Resultados del viaje 05-Integrando el sistema de alerta de voz




Figura 140: Circuito integral viaje 05
Fuente: Imagen propia



Figura 141: Detección nocturna-Clase NE-0.59
Fuente: Imagen propia



Figura 142: Detección nocturna-Clase NE-0.82
Fuente: Imagen propia




Figura 143: Detección nocturna-Clase NC-0.56
Fuente: Imagen propia




Figura 144: Detección nocturna-Clase VM_30-0.83
Fuente: Imagen propia

5. CONCLUSIONES

5.1. Conclusiones

La presente investigación ha logrado cumplir de manera efectiva con cada uno de los objetivos específicos planteados en su etapa inicial, lo que a su vez ha permitido alcanzar el objetivo general propuesto. Los resultados obtenidos han dado lugar a hallazgos significativos que respaldan de forma sólida las hipótesis formuladas al inicio del estudio.

- **OG:** Desarrollar técnicas de inteligencia artificial, basadas en redes neuronales convolucionales (CNN) que permitan mejorar la seguridad vial en las vías principales de la ciudad de Ayacucho.

La implementación de técnicas de inteligencia artificial basadas en redes neuronales convolucionales (CNN) permitió desarrollar un sistema eficiente de detección y clasificación automatizada de señalizaciones verticales, contribuyendo significativamente a la mejora de la seguridad vial en las vías principales de la ciudad de Ayacucho. El modelo entrenado con la arquitectura YOLOv8m demostró un desempeño altamente preciso, alcanzando métricas sobresalientes como una precisión y recall promedio de 0.997, y velocidades de inferencia de hasta 55.1 ms por imagen, garantizando su viabilidad para aplicaciones en tiempo real. Además, la integración de un sistema de alertas por voz optimizado permitió emitir advertencias inmediatas y sincronizadas durante pruebas en contextos urbanos reales, replicando condiciones dinámicas de tránsito en Ayacucho. A pesar de desafíos como el deterioro de señalizaciones, topografía irregular y deficiencias normativas, el sistema mostró robustez y adaptabilidad, posicionándose como una solución innovadora y efectiva para fortalecer la prevención de accidentes y optimizar la toma de decisiones del conductor en entornos urbanos complejos.

- **O1:** Desarrollar la arquitectura del modelo, basado en redes neuronales convolucionales (CNN), que permita la detección, clasificación de 14 señalizaciones verticales basado en el Manual de dispositivos de control del tránsito automotor.

Se desarrolló una arquitectura de detección basada en el modelo YOLO, adaptada para identificar y clasificar 14 tipos de señalizaciones verticales conforme al Manual de Dispositivos de Control del Tránsito Automotor. La implementación permitió una detección precisa, incluso en condiciones adversas como señalizaciones parcialmente ocultas o deterioradas. Además, las pruebas de campo reflejaron la efectividad del modelo para identificar señales regulatorias, preventivas, restrictivas e informativas con altos niveles de confianza, lo que valida su viabilidad técnica y operativa. Esto no solo respalda la hipótesis planteada, sino que también evidencia el potencial de las técnicas

de inteligencia artificial en la mejora de la seguridad vial a través de soluciones automatizadas y en tiempo real.

- **02:** Al simular el entrenamiento del modelo, basado redes neuronales convolucionales (CNN), se logra una mayor precisión de clase, recall y velocidades de inferencia ultrarrápidos, evitando el sobreajuste.

Se logró con éxito entrenar el modelo, estructurado en la arquitectura YOLOv8m y entrenado durante 104 épocas, demostrando una capacidad notable para alcanzar altos niveles de exactitud, con métricas destacadas como una precisión media (mAP@0.5) de 0.993, mAP@0.5:0.95 de 0.992, precisión de 0.997 y recall de 0.997. Estas cifras reflejan un rendimiento sólido y consistente del sistema, con una detección casi perfecta de señales de tránsito verticales, incluso en condiciones desafiantes. Además, el uso de la técnica de Early Stopping evitó el sobreajuste y optimizó el uso de los recursos computacionales. El modelo también se destacó por sus tiempos de procesamiento ultrarrápidos, con 0.3 ms para el preprocesamiento, 55.1 ms en inferencia y 0.9 ms en postprocesamiento, lo cual lo convierte en una solución viable para aplicaciones de seguridad vial en tiempo real. En conjunto, los resultados validan la eficiencia y precisión del modelo, consolidando su potencial como herramienta tecnológica en contextos urbanos.

- **03:** Determinar como la implementación del modelo basado en redes neuronales convolucionales (CNN) permite el desarrollo de un software para la detección automatizada de señalizaciones verticales, integrando un sistema de alertas por voz optimizado que garantice una reproducción inmediata y sincrónica, fundamental para la emisión oportuna de advertencias en materia de seguridad vial.

a implementación del modelo basado en redes neuronales convolucionales (CNN) permitió el desarrollo exitoso de un software de detección automatizada de señalizaciones verticales, el cual integra un sistema de alertas por voz optimizado para garantizar una reproducción inmediata y sincrónica. Este sistema fue validado mediante simulaciones vehiculares reales en las vías de la ciudad de Ayacucho, demostrando su eficacia para identificar y clasificar señales de tránsito en tiempo real, incluso en entornos urbanos complejos caracterizados por calles estrechas, topografía irregular, señalización deteriorada y deficiencias normativas. La integración del sistema de voz proporcionó mensajes auditivos claros y oportunos que fortalecen la capacidad preventiva del conductor y promueven una conducción más segura, al reducir los tiempos de reacción ante situaciones críticas en la vía. En conjunto, estos hallazgos evidencian que el sistema propuesto no solo es técnicamente funcional, sino también viable para aplicaciones en seguridad vial en contextos reales y exigentes.

5.2. Recomendaciones

- Ampliar la base de datos de señalizaciones para entrenamiento. Si bien se trabajó con 14 tipos de señalizaciones verticales, incorporar un conjunto más amplio de clases y ejemplos visuales (incluyendo señales deterioradas, parcialmente obstruidas o en ángulos no ideales) fortalecerá la capacidad de generalización del modelo y su precisión en entornos más diversos.
- Integrar sensores complementarios (GPS, LIDAR o IMU) La incorporación de datos de geolocalización (GPS) y sensores inerciales permitirá complementar el análisis visual con contexto espacial y de movimiento, lo que favorecerá la sincronización de alertas y una mejor gestión del sistema de navegación predictiva.
- Incluir una mayor variedad de condiciones climáticas y horarios .Se recomienda ampliar la ejecución de las simulaciones también bajo condiciones climáticas adversas (lluvia, neblina, sol intenso) . Esto permitirá evaluar con mayor amplitud la robustez del modelo frente a variaciones en la iluminación y visibilidad, aspectos clave en un sistema de asistencia en tiempo real.
- Evaluar el rendimiento del modelo con distintos tipos de vehículos. La investigación se centró en simulaciones desde una motocicleta, para ampliar el modelo se recomienda incluir pruebas desde vehículos con diferentes alturas de cámara (como automóviles, camionetas o buses) de manera que se pueda comparar el rendimiento del modelo ante cambios en el ángulo de visión y cobertura del entorno, mejorando así su adaptabilidad y precisión en distintos contextos urbanos.
- Aplicar técnicas de aumento de datos (Data Augmentation) más agresivas. El uso más intensivo de técnicas de data augmentation como rotaciones, cambios de brillo, recortes aleatorios, desenfoques y simulación de ruido , generará un conjunto de entrenamiento más robusto, preparando al modelo para enfrentar variaciones visuales impredecibles que ocurren en entornos urbanos reales.

5.3. Trabajos futuros

- Expansión del modelo a señalizaciones horizontales y semaforización. Una línea de trabajo futura consiste en adaptar el modelo de detección para identificar marcas viales horizontales (líneas de cruce peatonal, flechas de giro, límites de carril) y semáforos. Esto permitiría construir un sistema integral de interpretación del entorno vial urbano.
- Desarrollo de un sistema de asistencia para personas con discapacidad visual. A partir del sistema de detección y alertas por voz, se puede desarrollar una aplicación orientada a la movilidad segura de personas con discapacidad visual,

mediante dispositivos portátiles que informen sobre señales y condiciones del entorno vial en tiempo real.

- Integración con sistemas de navegación y mapas inteligentes. Un siguiente paso sería la vinculación del sistema con plataformas de navegación (como OpenStreetMap o Google Maps) para ofrecer rutas que prioricen la seguridad vial, tomando en cuenta la presencia o ausencia de señalización adecuada.
- Entrenamiento del modelo con datos en tiempo real mediante edge computing. Implementar el modelo en dispositivos embebidos (como Jetson Nano o Raspberry Pi con aceleración de GPU) para realizar procesamiento en el borde (edge computing), eliminando la necesidad de conexión a servidores externos y habilitando el uso en zonas con conectividad limitada.
- Aplicación del modelo en vehículos autónomos o sistemas ADAS. El sistema puede ser escalado e integrado como parte de una arquitectura de sistemas avanzados de asistencia al conductor (ADAS) o como módulo de percepción en vehículos autónomos de nivel 3 o superior, contribuyendo a la toma de decisiones automatizada en entornos urbanos complejos.

- Alvia Párraga, A. E., & Linares Giler, S. (2024). Accidentes de tránsito, un problema de salud pública: revisión sistemática. *Revista Científica Arbitrada Multidisciplinaria PENTACIENCIAS*, 6(3), 313-332. <https://doi.org/10.59169/pentaciencias.v6i3.1101>
- Arenas, A. (2016). *Diseño de un sistema de clasificación de señales de tránsito vehicular utilizando redes neuronales convolucionales* [Tesis para optar por el Título Profesional en Ingeniería Informática y de Sistemas]. Universidad San Ignacio de Loyola.
- 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.
- Bhuvaneshwari, B., Abbijeet, R., ... Priyadharshini, C. S. (2025). Traffic Sign Classification And Voice Alert System Using Convolutional Neural Network. *Procedia Computer Science*, 252, 10. <https://doi.org/10.1016/j.procs.2025.01.060>
- Brownlee, J. (2020). Failure of Classification Accuracy for Imbalanced Class Distributions. *Machine Learning Mastery*. <https://machinelearningmastery.com/failure-of-accuracy-for-imbalanced-class-distributions/>
- Caballero Romero, A. (2014). *Metodología integral innovadora para planes y tesis: La metodología del cómo formularlos*. Cengage Learning.
- Cedeño-Alcívar, B. J., & Mogrovejo, D. (2023). Estrategia de seguridad vial para la reducción de siniestros de tránsito Provincia de Manabí. *Revista Científica Multidisciplinaria Arbitrada YACHASUN*, 7(13), 17. <https://doi.org/10.46296/yc.v7i13.0356>
- Chen, H., Ali, M. A., ... Abdulghafor, R. (2024). Computational methods for automatic traffic signs recognition in autonomous driving on road: A systematic review. *Results in Engineering*, 24, 19. <https://doi.org/10.1016/j.rineng.2024.103553>
- Chollet, F., & Allaire, J. (2018). *Deep Learning with R*. Manning Publications.
- 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>
- Donmez, B., MacDonald, A. D., ... Boyle, L. N. (2023). Road user behavior: Describing, inferring, predicting and beyond. *ScienceDirect*. <https://www.sciencedirect.com/science/article/pii/S2590198223001793>
- Economic, U. N., & for Western Asia, S. C. (2014). *Road traffic safety refers to methods and measures for reducing the risk of a person using the road network for being killed or seriously injured* [Retrieved from UNESCWA website]. <https://archive.unescwa.org/road-traffic-safety>

- Effective Health Care Program. (2022). *Appendix: Test Performance Metrics*. <https://effectivehealthcare.ahrq.gov/products/test-performance-metrics/appendixes>
- Estado del tráfico una descripción general. (2024). *ScienceDirect Topics*. <https://www.sciencedirect.com/topics/computer-science/traffic-condition>
- Evidentlyai. (2023). *Accuracy vs. precision vs. recall in machine learning: what's the difference?* <https://www.evidentlyai.com/classification-metrics/accuracy-precision-recall>
- Fuller, R. (2008). Psychological Aspects of Road User Behaviour. <https://doi.org/10.13140/RG.2.1.4762.4164>
- 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.
- Global, I. (2023). Road Infrastructure Definition. *IGI Global Scientific Publishing*. <https://www.igi-global.com/dictionary/convergence-and-equality-of-road-infrastructure/55615>
- 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>
- Han, Y., Wang, F., ... Li, X. (2024). EDN-YOLO: Multi-scale traffic sign detection method in complex scenes. *Digital Signal Processing*, 153, 13. <https://doi.org/10.1016/j.dsp.2024.104615>
- Highways, G. (2024). *Peru's serious road safety problem* [Retrieved August 4, 2025, from Global Highways website]. <https://www.globalhighways.com/wh11/news/perus-serious-road-safety-problem>
- Jameel, B. K., & Evdorides, H. (2018). Assessment of safer road user behaviour. *ResearchGate*. https://www.researchgate.net/publication/329457019_Assessment_of_safer_road_user_behaviour
- 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>
- Lasse, R. (2018). *Inteligencia artificial: 101 cosas que debes saber hoy sobre nuestro futuro*. Alienta Editorial.
- Manual de Dispositivos de Control del Tránsito Automotor. (2024). *Manual de Dispositivos de Control del Tránsito Automotor* [Manual oficial]. Ministerio de Transportes y Comunicaciones. Lima, Perú.
- Matos Levano, J. A. (2020). *Implementación de un sistema de señalización vial para la prevención de accidentes de tránsito en la Avenida Fernando Wiesse, San Juan de Lurigancho, Lima – 2020* [Tesis para obtener el título profesional de

- Ingeniero Civil]. Universidad César Vallejo [Asesor: Benites Zúñiga, José Luis. Línea de investigación: Diseño de Infraestructura Vial]. <https://hdl.handle.net/20.500.12692/54877>
- 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>
- mundial de la salud, O. (2023). *Road traffic injuries* [Retrieved August 4, 2025, from World Health Organization website]. <https://www.who.int/news-room/fact-sheets/detail/road-traffic-injuries>
- 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.
- 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.
- Organización Mundial de la Salud. (2024). Los cinco pilares de la seguridad vial [Marco integral de la OMS para mejorar la seguridad vial a nivel mundial]. <https://iucpol.com/oms-seguridad-vial-5-pilares/>
- Organización Panamericana de la Salud. (2024). Seguridad vial [Organización Panamericana de la Salud/Organización Mundial de la Salud]. OPS/OMS. <https://www.paho.org/es/temas/seguridad-vial>
- Qiu, J., Zhang, W., ... Zhou, H. (2025). DP-YOLO: A lightweight traffic sign detection model for small object detection. *Digital Signal Processing*, 165, 15. <https://doi.org/10.1016/j.dsp.2025.105311>
- Quispe Condor, E. (2024). *Diseño de una red neuronal para la predicción de accidentes de tránsito en la carretera Central tramo: Tarma-La Merced, Junín 2022* [Tesis para optar el título profesional de Ingeniero Civil]. Universidad Nacional del Centro del Perú.
- Ramachandran, P., Zoph, B., & Le, Q. V. (2017). Searching for activation functions. *arXiv preprint*. <https://arxiv.org/abs/1710.05941>
- Ramos Zúñiga, M. V. (2021). *Detección y reconocimiento automatizado de señales preventivas en inventarios viales* [Tesis para obtener el título profesional de Ingeniero Civil]. Universidad Nacional de Ingeniería [Asesor: MSc. Leonardo Flores Gonzalez].
- 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>

- 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>
- Russell, S., & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach* (4th). Pearson.
- Sifuentes Rodriguez, C. O., & Alarco Basaldua, G. (2023, noviembre). *Propuesta de Mejora en la Seguridad Vial en Intersecciones de Alto Tránsito a través de medidas de Bajo Costo* [Trabajo de Suficiencia Profesional para optar el título profesional de Ingeniero Civil]. Universidad Peruana de Ciencias Aplicadas.
- Sun, Y., Li, X., ... Wang, Q.-G. (2025). Evolving traffic sign detection via multi-scale feature enhancement, reconstruction and fusion. *Digital Signal Processing*, 160, 9. <https://doi.org/10.1016/j.dsp.2025.105028>
- Távora Idrogo, J. G. (2019). *Modelo de reconocimiento automático de señales de tránsito vehicular mediante aprendizaje profundo de redes neuronales convolucionales* [Tesis para obtener el título profesional de Ingeniero Informático]. Universidad Nacional de Trujillo.
- 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/>
- 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.
- Vizcaya, R., Flores Albino, J. M., ... Lazcano-Salas, S. (2017). Desempeño de una red neuronal convolucional para clasificación de señales de tránsito [Becario CONACYT con No. CVU 712316]. *Journal CIM Vol. 5. Núm. 2, Coloquio de Investigación Multidisciplinaria 2017*, 9.
- 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>
- 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
- Zhao, R., Tang, S. H., ... Rahim, S. A. (2024). Enhancing autonomous driving safety: A robust traffic sign detection and recognition model TSD-YOLO. *Signal Processing*, 225, 15. <https://doi.org/10.1016/j.sigpro.2024.109619>

6. ANEXOS

6.1. Panel fotográfico: Recolección de fotografías en campo



Figura 145: Verificación del estado situacional de la señalización (R-27A)
Fuente: Imagen propia



Figura 146: Señal de prohibición (R-27A) Ubicada en el Jr. Tres Máscaras
Fuente: Imagen propia



Figura 147: Señal preventiva (P-33A)-Ubicada inadecuadamente
Fuente: Imagen propia



Figura 148: Señal preventiva (P-33A), obstaculizando el paso peatonal
Fuente: Imagen propia




Figura 149: Señal de restricción (R-30)
Fuente: Imagen propia



Figura 150: Señal (R-27A)-Notoriamente desgastada
Fuente: Imagen propia




Figura 151: Incumplimiento de la señal (R-27A)
Fuente: Imagen propia



Figura 152: Incumplimiento de la señal Prohibido Estacionar
Fuente: Imagen propia



Figura 153: Señal (R-27A) presenta inclinación lateral considerable
Fuente: Imagen propia



Figura 154: Señal (R-27A) sin parante de soporte estructural independiente
Fuente: Imagen propia



Figura 155: Señal (R-27A) sujeta directamente al poste de alumbrado público
Fuente: Imagen propia



Figura 156: Ausencia de señalización vertical
Fuente: Imagen propia



Figura 157: Instalación de las cámaras de investigación
Fuente: Imagen propia

6.2. Matriz de consistencia y operacionalización

La matriz de consistencia y operacionalización de variables, se detallan a continuación:

Cuadro : Matriz de consistencia.

Problemas principal	Objetivos general	Hipótesis general	Variables	Metodología
¿De qué manera las técnicas de inteligencia artificial , basadas en redes neuronales convolucionales (CNN), mejoran la seguridad vial en las vías principales de la ciudad de Ayacucho?	Desarrollar técnicas de inteligencia artificial, basadas en redes neuronales convolucionales(CNN) que permitan mejorar la seguridad vial en las vías principales de la ciudad de Ayacucho.	Las técnicas de inteligencia artificial , basadas en redes neuronales convolucionales (CNN) permiten mejorar significativamente, la seguridad vial en las vías principales de la ciudad de Ayacucho.	Independiente X: Técnicas de inteligencia artificial <u>Dimensiones</u> – Arquitectura del modelo – Diseño del modelo – Entrenamiento del modelo – Resultados e implementación del modelo Dependiente Y: Seguridad Vial <u>Dimensiones</u> – Predicción de la detección – Eficiencia del procesamiento – Tipología de las señales detectadas	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 de estudio está constituida por 3,000 imágenes de señalizaciones verticales capturadas en las principals vías de la ciudad de Ayacucho. Estas imágenes fueron obtenidas mediante observación sistemática no participante. Muestra: – La muestra será intencional ,seleccionando imágenes que representen adecuadamente a las señalizaciones verticales.Se selecciono una muestra representativa de 2250 imágenes. Técnica: – Observación sistemática no participante Instrumento: – Cámaras IMOU
Problemas específico	Objetivos específico	Hipótesis específico		
¿Cómo la arquitectura del modelo, basado en redes neuronales convolucionales(CNN) permite la detección , clasificación de 14 señalizaciones verticales basado en el Manual de dispositivos de control del tránsito automotor?	Desarrollar la arquitectura del modelo, basado en redes neuronales convolucionales (CNN), que permita la detección, clasificación de 14 señalizaciones verticales basado en el Manual de dispositivos de control del tránsito automotor.	La arquitectura del modelo, basado en redes neuronales convolucionales (CNN), permite la detección , clasificación de 14 señalizaciones verticales basado en el Manual de dispositivos de control del tránsito automotor.		
¿En qué medida el entrenamiento del modelo basado en redes neuronales convolucionales (CNN) logra una mayor precisión de clase,recall y velocidades de inferencia ultrarrápidos, evitando el sobreajuste?	Al simular el entrenamiento del modelo, basado redes neuronales convolucionales (CNN), se logra una mayor precisión de clase, recall y velocidades de inferencia ultrarrápidos, evitando el sobreajuste.	El entrenamiento del modelo , basado redes neuronales convolucionales (CNN) logra una mayor precisión de clase, recall y velocidades de inferencia ultrarrápidos, evitando el sobreajuste.		
¿De qué manera la implementación del modelo , basado en redes neuronales convolucionales (CNN) permite el desarrollo de un software para la detección automatizada de señalizaciones verticales, integrando un sistema de alertas por voz optimizado que garantice una reproducción inmediata y sincrónica,fundamental para a emisión oportuna de advertencias en materia de seguridad vial?	Determinar como la implementación del modelo basado en redes neuronales convolucionales (CNN) permite el desarrollo de un software para la detección automatizada de señalizaciones verticales, integrando un sistema de alertas por voz optimizado que garantice una reproducción inmediata y sincrónica,fundamental para la emisión oportuna de advertencias en materia de seguridad vial.	La implementación del modelo, basado en redes neuronales convolucionales (CNN) permite el desarrollo de un software para la detección automatizada de señalizaciones verticales, integrando un sistema de alertas por voz optimizado que garantice una reproducción inmediata y sincrónica, fundamental para la emisión oportuna de advertencias en materia de seguridad vial.		

Fuente: Elaboración propia.

Cuadro : Matriz de Operacionalización de variables.

Variable	Definición conceptual	Dimensiones	Indicadores	Unidad de medida
Independiente (X): Técnicas de inteligencia artificial	Constituyen un conjunto de métodos computacionales y algoritmos que permiten a las máquinas simular procesos cognitivos humanos para realizar tareas complejas de manera autónoma. En el contexto de la seguridad vial, estas técnicas incluyen algoritmos de aprendizaje automático, redes neuronales, visión por computadora y procesamiento de datos en tiempo real, que pueden analizar patrones, detectar anomalías y tomar decisiones predictivas para prevenir accidentes de tránsito mediante el reconocimiento y análisis de situaciones de riesgo en las vías públicas.	1. Arquitectura del modelo	- Número de capas de la RNA	Conteo (n)
			- Tipo de capas	Categórico
			- Tamaño de las capas	Conteo (n)
			- Función de activación	Categórico
		2. Diseño del modelo	- Tasa de aprendizaje	(%)
			- Número de épocas de entrenamiento	Conteo (n)
			- Momento (momentum)	(%)
			- Factor de decaimiento del aprendizaje	(%)
		3. Entrenamiento del modelo	- 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	(%)
Dependiente (Y): Seguridad Vial	Conjunto de medidas, estrategias y condiciones que garantizan la protección de la vida e integridad física de todos los usuarios de las vías públicas, incluyendo conductores, pasajeros, peatones y ciclistas. Comprende la prevención de accidentes de tránsito a través del control de factores de riesgo, la implementación de infraestructura adecuada, el cumplimiento de normativas de tránsito y la promoción de comportamientos responsables, con el objetivo de minimizar la probabilidad de ocurrencia de siniestros viales.	1. Prevención de accidentes	- Índice de reducción de siniestros	(%)
		2. Detección de situaciones de riesgo	- Velocidad promedio de los vehículos	(km/h)
			- Velocidad máxima registrada	(km/h)
			- Velocidad mínima registrada	(km/h)
		3. Gestión del tráfico	- Reducción del tiempo de viaje y mejora en el flujo vehicular	(veh/tiempo)
		4. Respuesta a emergencias	- Reducción de tiempo	(%)
			- Precisión de detección	(%)
			- Consumo de recursos	(%)

Fuente: Elaboración propia.

**UNSCH**FACULTAD DE
INGENIERÍA
DE MINAS, GEOLOGÍA Y CIVIL**ACTA DE SUSTENTACIÓN DE TESIS N° 051-2025-FIMGC****PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO CIVIL**

En la Universidad Nacional de San Cristóbal de Huamanga de la ciudad de Ayacucho, en cumplimiento a la **RESOLUCIÓN DECANAL N° 396-2025-FIMGC-D**, a los **treinta y un días** del mes de **octubre de 2025**, siendo las **10:00 a.m.**, reunidos en el **Auditorio de la Escuela Profesional de Ingeniería Civil**, bajo la presidencia del **MSc. Ing. José Ernesto ESTRADA CARDENAS**, y los miembros: **MSc. Ing. Hemerson LIZARBE ALARCON**, **MSc. Ing. Edward LEON PALACIOS** y **MSc. Ing. Moisés Nico BARBARÁN ORIUNDO**, actuando como secretario docente el **Ing. Saul Walter RETAMOZO FERNÁNDEZ**, para proceder a la sustentación de tesis para optar el **Título Profesional de Ingeniero Civil**, del bachiller:

EDUARDO JESUS URBINA DOMINGUEZ

Quien presentó la tesis denominada:

“PROPUESTA DE MEJORA DE LA SEGURIDAD VIAL EN LAS VÍAS PRINCIPALES DE LA CIUDAD DE AYACUCHO A TRAVÉS DE LA IMPLEMENTACIÓN DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL”

Los señores miembros del jurado, luego de expuesta la tesis y absueltas las preguntas, deliberaron y declararon:

Aprobado con Diecisiete (17)

Siendo las **12:00 p.m.** del día **31 de octubre de 2025**, culmina el acto de sustentación de tesis, y en conformidad con lo actuado, los miembros del jurado firman al pie del presente.

MSc. José Ernesto ESTRADA CÁRDENAS
Presidente

MSc. Hemerson LIZARBE ALARCON
Miembro

MSc. Moisés Nico BARBARÁN ORIUNDO
Miembro

MSc. Edward LEON PALACIOS
Miembro - Asesor

Ing. Saul Walter RETAMOZO FERNANDEZ
Secretario docente de la FIMGC

FACULTAD DE INGENIERÍA
DE MINAS Y CIVIL
Av. Independencia S/N
Ciudad Universitaria
Central Tel. 066 312510
Anexo 151



CONSTANCIA DE ORIGINALIDAD DE TRABAJO DE INVESTIGACIÓN

CONSTANCIA N° 030-2025-FIMGC/ASIH

El que suscribe; responsable verificador de originalidad de trabajos de tesis de pregrado con el software Turnitin, de la Escuela 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-UNSH-CU**, Reglamento de Originalidad de Trabajos de Investigación de la Universidad Nacional San Cristóbal de Huamanga y **Resolución Decanal N° 697-2024-FIMGC-UNSH-D**, dejo constancia de originalidad de trabajo de investigación, que el/la Sr./Srta.

Apellidos y Nombres : Eduardo Jesus URBINA DOMINGUEZ
Escuela Profesional : INGENIERÍA CIVIL
Título de la Tesis : " PROPUESTA DE MEJORA DE LA SEGURIDAD VIAL
EN LAS VÍAS PRINCIPALES DE LA CIUDAD DE
AYACUCHO A TRAVÉS DE LA IMPLEMENTACIÓN DE
TÉCNICAS DE INTELIGENCIA ARTIFICIAL"
Evaluación de la Originalidad : 25 % Índice de Similitud
Identificador de la entrega : 2849124491

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, 18 de diciembre del 2025



UNIVERSIDAD NACIONAL DE
SAN CRISTÓBAL DE HUAMANGA
Facultad de Ingeniería de Minas, Geología y Civil

Mg. Ing. Alex Sander IRCANAUPA HUAMANTI
Verificador de Originalidad de Trabajos de Tesis de Pregrado
Escuela de Formación Profesional de Ingeniería Civil

"PROPUESTA DE MEJORA DE LA SEGURIDAD VIAL EN LAS VÍAS PRINCIPALES DE LA CIUDAD DE AYACUCHO A TRAVÉS DE LA IMPLEMENTACIÓN DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL"

por Eduardo Jesus URBINA DOMINGUEZ

Fecha de entrega: 18-dic-2025 04:33p. m. (UTC-0500)

Identificador de la entrega: 2849124491

Nombre del archivo: Te_Eduardo_Jesus_Urbina_Dominguez.pdf (5.78M)

Total de palabras: 30655

Total de caracteres: 189265

"PROPUESTA DE MEJORA DE LA SEGURIDAD VIAL EN LAS VÍAS PRINCIPALES DE LA CIUDAD DE AYACUCHO A TRAVÉS DE LA IMPLEMENTACIÓN DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL"

INFORME DE ORIGINALIDAD

25%	12%	3%	21%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	Submitted to Universidad Nacional de San Cristóbal de Huamanga Trabajo del estudiante	18%
2	hdl.handle.net Fuente de Internet	1%
3	repositorio.uni.edu.pe Fuente de Internet	1%
4	www.slideshare.net Fuente de Internet	<1%
5	dspace.unitru.edu.pe Fuente de Internet	<1%
6	repositorio.ucv.edu.pe Fuente de Internet	<1%
7	cdn.www.gob.pe Fuente de Internet	<1%
8	roadsafety.piarc.org Fuente de Internet	<1%
9	alicia.concytec.gob.pe Fuente de Internet	<1%

repositorio.uncp.edu.pe

10	Fuente de Internet	<1 %
11	dspace.esPOCH.edu.ec Fuente de Internet	<1 %
12	Submitted to Grupo IOE Trabajo del estudiante	<1 %
13	idus.us.es Fuente de Internet	<1 %
14	revvialibre.com.mx Fuente de Internet	<1 %
15	www.who.int Fuente de Internet	<1 %
16	www.ridaa.unicen.edu.ar Fuente de Internet	<1 %
17	www.fundacionaleatica.org Fuente de Internet	<1 %
18	repositorio.usil.edu.pe Fuente de Internet	<1 %
19	repositorio.unasam.edu.pe Fuente de Internet	<1 %
20	Submitted to Universidad Andina del Cusco Trabajo del estudiante	<1 %
21	repositorio.unsch.edu.pe Fuente de Internet	<1 %
22	repository.unad.edu.co Fuente de Internet	<1 %
23	www.skynetsapiens.com Fuente de Internet	<1 %

24

Submitted to Universidad Católica de Santa
María

Trabajo del estudiante

<1 %

25

www.aacarreteras.org.ar

Fuente de Internet

<1 %

Excluir citas

Activo

Excluir coincidencias < 30 words

Excluir bibliografía

Activo