



UNIVERSIDAD CÉSAR VALLEJO

FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE
SISTEMAS

Algoritmo inteligente para la clasificación de vehículos y extracción
de caracteres de las placas vehiculares

TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE:

Ingeniero de Sistemas

AUTORES:

Outten Campos, Eduardo Junior (orcid.org/0000-0002-1923-2894)

Romero Pacheco, Jhonatan Jhefersson (orcid.org/0000-0001-9645-5306)

ASESORES:

Dr. Necochea Chamorro, Jorge Isaac (orcid.org/0000-0002-3290-8975)

LÍNEA DE INVESTIGACIÓN:

Sistemas de Información y Comunicaciones

LÍNEA DE RESPONSABILIDAD SOCIAL UNIVERSITARIA:

Desarrollo económico, empleo y emprendimiento

LIMA - PERÚ

2023

DEDICATORIA

Dedicamos el presente proyecto a nuestras familias y seres queridos por el constante apoyo, palabras motivadoras y su amor incondicional. A nuestro asesor, por su guía durante el tiempo de realización de nuestro proyecto, por su compartir sus conocimientos para poder cumplir con el objetivo de forma exitosa.

AGRADECIMIENTO

Agradecemos a todas las personas que contribuyeron en este largo camino para poder finalizar la carrera de ingeniería de sistemas, a nuestra casa de estudios, la Universidad César Vallejo la cual nos permitió desarrollarnos como profesionales.

ÍNDICE DE CONTENIDOS

DEDICATORIA.....	ii
AGRADECIMIENTO.....	iii
RESUMEN	vii
ABSTRACT	viii
I. INTRODUCCIÓN	1
II. MARCO TEÓRICO	4
III. METODOLOGÍA	15
3.1 Tipo y diseño de investigación	15
3.2 Variable y Operacionalización	16
3.3 Población, muestra y unidad de análisis	19
3.4 Técnicas e Instrumentos de recolección de datos.....	20
3.5 Procedimientos.....	21
3.6 Método de análisis de datos.....	23
3.7 Aspectos éticos	24
IV. RESULTADOS.....	25
V. DISCUSIÓN	33
VI. CONCLUSIONES	35
VII. RECOMENDACIONES.....	36
REFERENCIAS.....	37
ANEXOS	42

ÍNDICE DE TABLAS

Tabla 1: Población de la investigación	19
Tabla 2: Muestra de investigación.....	19
Tabla 3: Técnicas e instrumento para cada indicador	20
Tabla 4: Cuadro-estadístico-del-indicador-de-precisión	25
Tabla 5. Cuadro-estadístico-del-indicador-de-recall.....	25
Tabla 6. Cuadro-estadístico-del-indicador-de-F1score	26
Tabla 7. Cuadro-estadístico-del-indicador-de-Precisión de reconocimiento de caracteres.....	26
Tabla 8. Medidas descriptivas de PCV: Precisión para la clasificación de vehículos	26
Tabla 9. Medidas descriptivas de RCV: Recall para la clasificación de vehículos	27
Tabla 10. Medidas descriptivas de FCV: F1score para la clasificación de vehículos	27
Tabla 11. Medidas descriptivas de PRC: Precisión de reconocimiento de caracteres de las placas vehiculares.....	28
Tabla 12. Resumen de Indicadores.....	28
Tabla 13. Tabla-de-indicadores-de-las-hipótesis-estadísticas.....	29
Tabla 14. Tabla-de-pruebas-de-normalidad-del-indicador-de-precisión	29
Tabla 15. Tabla-de-pruebas-de-normalidad-del-indicador-de-recall.....	29
Tabla 16. Tabla-de-pruebas-de-normalidad-del-indicador-de-f1score	30
Tabla 17. Tabla-de-pruebas-de-normalidad-del-indicador-de-Precisión de reconocimiento de caracteres	30
Tabla 18. Tabla-de-rango-de-wilcoxon-del-indicador-de-precisión.....	31
Tabla 19. Tabla-de-rango-de-wilcoxon del indicador de recall	31
Tabla 20. Tabla-de-rango-de-wilcoxon-del-indicador-de-f1score	32
Tabla 21. Tabla-de-rango-de-wilcoxon-del-indicador-de-precisión de reconocimiento de caracteres	32
Tabla 22. Matriz de operacionalización de variable.....	42
Tabla 23: Matriz de consistencia	43

ÍNDICE DE GRÁFICOS Y FIGURAS

Figura 1: Arquitectura Darknet	10
Figura 2: Las fases de metodología SCRUM	11
Figura 3: Metodología de construcción.....	13
Figura 4: Modelos de metodología CommonKads	14
Figura 5: Diseño Pre-Experimental	16
Figura 6: Fórmula de RECALL (Leite et al. 2022)	17
Figura 7: Fórmula de PRECISIÓN (Leite et al. 2022).....	18
Figura 8: Fórmula de F1 SCORE (Leite et al. 2022)	18
Figura 9: Fórmula de precisión de reconocimiento (Shim et al. 2022)	18
Figura 10: Flujograma del procedimiento del proyecto.....	21
Figura 11: Metodología de construcción.....	23

RESUMEN

Este estudio se titula "Un algoritmo inteligente para la clasificación de vehículos y la extracción de caracteres de matrículas". La investigación aborda la cuestión de los algoritmos que no mezclan 2 funcionalidades y, por tanto, su objetivo principal era crear un algoritmo inteligente para categorizar vehículos y extraer caracteres de las matrículas. Para lograr esto, se empleó la metodología de desarrollo CommonKads para el desarrollo de algoritmos y SCRUM sirvió como enfoque de gestión de proyectos. La investigación utilizó varias tecnologías como YOLO (You Only Look Once Algorithm), EASYOCR (Optical Character Recognition), Google COLAB, Python, TensorFlow y más. Este estudio sigue un enfoque preexperimental aplicado con una perspectiva cuantitativa e involucró un conjunto de datos de 30 fotografías de vehículos. La observación fue la técnica de investigación elegida y las hojas de registro de observación fueron las herramientas de recolección de datos empleadas.

Palabras clave: Reconocimiento de imágenes, YOLO, OCR, Deep learning.

ABSTRACT

This study is titled “An Intelligent Algorithm for Vehicle Classification and License Plate Character Extraction.” The research addresses the question of algorithms that do not mix 2 functionalities and, therefore, its main objective was to create an intelligent algorithm to categorize vehicles and extract characters from license plates. To achieve this, the CommonKads development methodology was employed for algorithm development and SCRUM served as the project management approach. The research used various technologies such as YOLO (You Only Look Once Algorithm), EASYOCR (Optical Character Recognition), Google COLAB, Python, TensorFlow and more. This study follows a pre-experimental approach applied with a quantitative perspective and involved a data set of 30 vehicle photographs. Observation was the chosen research technique and observation recording sheets were the data collection tools used.

Keywords: Image recognition, YOLO, OCR, Deep learning

I. INTRODUCCIÓN

Actualmente, el uso de los algoritmos de aprendizaje automático, permiten estructurar determinados patrones, como también analizar data, lo cual es útil para realizar predicciones y automatizar tareas; como, por ejemplo, la extracción de caracteres de placas vehiculares y la clasificación de los vehículos en categorías o grupos (Sandoval, 2018). En ese sentido, algunos algoritmos de aprendizaje, como el uso de una red neuronal convolucional, a través de un entrenamiento adecuado, logra reconocer objetos específicos y demasiado pequeños, desafiando diferentes ángulos, sombras o posiciones poco claras dentro de la imagen, permitiendo un monitoreo más eficiente de los vehículos dentro de un país.

A nivel general, la clasificación de vehículos se define como un proceso que permite agrupar a los medios de transporte a través de diversas características. Cabe mencionar que, esta clasificación es general y puede variar según el país, la regulación y la evolución de la tecnología. En ese sentido, la categorización se realiza de acuerdo al propósito o el contexto, por ejemplo, según Homologación Vehículos (2021) menciona que, a nivel intencional en España, la clasificación se basa en cuatro categorías: Categoría M (coches y autobuses), Categoría N (furgonetas y camiones), Categoría O (Remolques) y Categoría L (Tres ruedas).

A nivel nacional, el Ministerio de Comunicaciones planteó cuatro grupos de categorización de vehículos: Categoría L (Vehículos automotores con menos 4 ruedas), Categoría M (Vehículos automotores de 4 ruedas o más diseñados para el transporte de personas), Categoría N (Vehículos automotores de 4 ruedas o más diseñados para el transporte de mercancías), Categoría O (Remolques y semirremolques) (El Peruano, 2006; Tarazona, 2018). Por ello, se concluye que la clasificación de vehículos en Perú se basa en varios criterios, que incluyen el tipo de vehículo, su capacidad de carga, su uso y su propulsión.

Por otro lado, Tracklink (2022) menciona que las placas vehiculares en el Perú se clasifican de la siguiente manera: 1) Placas de uso particular, las cuales poseen un formato alfanumérico cuyo fondo es de color blanco con caracteres

negros; 2) Placas de uso comercial, aquellas que presentan un fondo amarillo con caracteres negros; 3) Placas de uso diplomático, caracterizadas por tener el fondo azul con caracteres blancos y poseen un formato alfanumérico especial; por último, 4) Placas de uso oficial, las cuales presentan un formato alfanumérico específico y presentan fondo rojo con caracteres blancos.

Respecto al algoritmo inteligente de clasificación de vehículos y extracción de placas, si bien es cierto que a nivel nacional no existe diversidad de estudios que realicen el desarrollo de esta herramienta tecnológica, a nivel internacional se ha logrado encontrar investigaciones enriquecedoras, como por ejemplo, Barbecho y Zhindón (2020) realizaron una investigación en la cual crearon un modelo de algoritmo de visión artificial, haciendo uso de las redes neuronales convolucionales y encontraron que, este tipo de inteligencia artificial, facilitaba la ubicación de los vehículos, haciendo uso de la extracción de los caracteres de las placas vehiculares, tomando en cuenta las redes neuronales convolucionales.

Teniendo en contexto sobre los algoritmos, extracción de caracteres y clasificación el análisis de esta investigación es desarrollar un algoritmo propio teniendo en cuenta los problemas que existen al momento de reconocer objetos con algunos algoritmos esto debido a que presentan bajos porcentajes en las métricas principales como la precisión, recall, la puntuación-F1 y la precisión de reconocimiento de caracteres, esto debido a que algunas imágenes son de bajo contraste, ruidosidad, borrosas, iluminación que no aporta, el bajo umbral que tienen o el ángulo de la imagen, así mismo muy pocas de ellas pueden realizar las estas funcionalidades al mismo tiempo. Ante estos puntos nuestra propuesta de desarrollo buscará tener buenos porcentajes en las métricas de precisión, f1.score, recall y precisión de reconocimiento de caracteres.

Por todo lo mencionado anteriormente, respecto a la justificación de acuerdo con lo revisado en la literatura e investigaciones nos revelan que algunos de los algoritmos o sistemas no cumplen con los resultados esperados, ya que estos sistemas no presentan imágenes con una óptima resolución. En este sentido Hasan, et al. (2021) mencionan que para que un algoritmo tenga mejores resultados se deben realizar entrenamientos constantes con gran

cantidad de datos que permitan evaluar cada uno de los rendimientos. Posteriormente, se encontró una investigación realizada en el contexto peruano encontró que acorde a un determinado sistema de reconocimiento de placas de vehículos a través de la visión computacional procesó 29 imágenes por segundo, lo cual permitió la mejora al acceso de un establecimiento de estacionamiento (Perez, 2022).

Por ello, es importante cuestionarnos según nuestro contexto las siguientes preguntas: ¿Nuestro algoritmo inteligente podrá clasificar los vehículos y extraer los caracteres de las placas vehiculares? Asimismo, se planteó sus cuestiones específicas los cuales son ¿Cómo el algoritmo inteligente clasificará los vehículos?, ¿Cómo el algoritmo inteligente detectará las placas vehiculares? Y ¿Cómo el algoritmo inteligente extraerá los caracteres de las placas vehiculares?

Por otro lado, el objetivo principal de esta investigación es desarrollar un algoritmo inteligente para la clasificación de vehículos y para la extracción de los caracteres de las placas vehiculares. Asimismo, se planteó los siguientes objetivos específicos: Desarrollar un algoritmo inteligente que clasifique los vehículos, Desarrollar un algoritmo inteligente que detecte las placas Y Desarrollar un algoritmo inteligente que extraiga los caracteres de las placas.

Por otra parte, se planteó como hipótesis general que es el siguiente el algoritmo inteligente clasificar los vehículos y extraer los caracteres de sus matrículas. Por otro lado, respecto a las hipótesis específicas se formuló que el algoritmo inteligente logra clasificar los vehículos, el algoritmo inteligente logra detectar las placas y el algoritmo inteligente logra extraer los caracteres de las placas vehiculares.

II. MARCO TEÓRICO

Dentro del contexto internacional, en relación con los antecedentes recaudados, se encontró diversidad de investigaciones que desarrollan las variables estudiadas a lo largo de la presente investigación.

En Bangladesh, Hazan, Wang, Hussain y Fatima (2021) en su investigación propusieron un modelo basado en el modelo de transferencia, que incorpora el modelo de datos, para la clasificación y reconocimiento de los tipos de vehículos nativos en Bangladesh, y la muestra fue conformada por el modelo CNN pre entrenado utilizando un método basado en ResNet-50 (red residual); como también tiene una muestra de 10 440 imágenes de vehículos basado en 13 categorías de vehículos de las carreteras de Bangladesh recopilación de un conjunto de datos de Deshi-BD, así mismo el entrenamiento fue compuesto por el 80% de los datos de imágenes y para validar el modelo se usaron el 20% de los datos de imágenes; como resultado destacó una precisión promedio de 97,9%, recall de 98,1% y F1-Score de 98.1% y una precisión de 98% obtenido del tipo de modelo ResNet-50. En conclusión, ResNet-50 superaron respectivamente los valores más altos en accuracy 98% y recall 98.1%.

En Taiwán, Srividhya, Kavitha, Lai, Maní y Khalaf (2022) propusieron presentar un algoritmo de perfil de contorno interno-externo (IOOPL) para detectar los tres límites del objeto, así mismo la metodología usada es experimental, dentro de la investigación se propuso la metodología de IOOPL con un algoritmo delta la cual permite eliminar las sombras y clasificar los vehículos, para la muestra se respaldaron con videos en tiempo real de 3910; como resultado se obtiene que el algoritmo delta tiene una precisión de 92% para las clasificaciones de vehículos. En conclusión, los algoritmos implicados ayudarán a mejorar la estimación de los parámetros del tráfico y el seguimiento de vehículos debido a los excelentes resultados que ofrecen en la reducción de sombras y la detección de vehículos.

En Pakistán, Shafi, Hussain, Ahmad, Kim, Choi, Ashraf y Din (2022) tuvieron como objetivo es idear un mecanismo robusto de detección y reconocimiento de matrículas vehiculares no estándar y transitoria, su metodología es empleada en una arquitectura de red neuronal convolucional profunda (CNN)

de 53 capas usando el algoritmo de detección de objetos YOLOv3, el conjunto de datos usado para las matrículas de vehículos son de 2131 imágenes de vehículos paquistaníes y para el conjunto de datos de caracteres se utilizan 571 imágenes de caracteres de matrícula; se obtuvo una precisión de detección de matrículas vehiculares del 97,82% y un reconocimiento de caracteres de 96%. En conclusión, la metodología propuesta produce una alta tasa de reconocimiento de matrículas y caracteres.

En Marruecos, Derrouz, Elbouziady, Abdelali, Thami, El Fkihi Y Bourzeix (2019) propusieron presentar un marco de clasificación de tipo de vehículos de dos capas basado en los parámetros 3D del vehículo y sus características locales, su metodología se basa en un marco de clasificación (3D_VTC) que se divide en 2 pasos las cuales son, la extracción de caracteres 3D que se realizó bajo el método de YOLO y extracción y clasificación en 2D aplicaron el histograma de gradiente orientado (HOG), el conjunto de datos utilizado fueron 60 videos y 75,230 imágenes anotadas en un cuadro delimitador y para las cuales se usó un sistema de visión estéreo en las áreas urbanas de Marruecos (MoVITS-DataSet); como resultado se obtiene que su enfoque muestra una precisión del 95%, así mismo realiza una correcta clasificación con los distintos tipos de vehículos en distintos desafíos; en conclusión el marco propuesto puede clasificar con precisión desde distintos ángulos de visión los vehículos.

Zhang, Yang, Bo y Lu (2019) en su trabajo de investigación propusieron mejorar la construcción de datos de logotipos los pre-entrenamiento multi-etapa, las predicciones multi-escalas y entre otras capas de profundidad y agrupación, donde se usó el algoritmo de una sola etapa (SS-VLD) debido a que es un método eficiente y simple para completar el reconocimiento y ubicación de objetos; como también 3015 fotografías de logotipos de 45 clases de vehículos de las empresas de automóviles de China las cuales fueron recopilados de página de internet, con una población de 2115 imágenes y 900 fotografías de muestra para la etapa de entrenamiento; como resultado se obtuvo una detección del 85% de precisión con un tiempo de espera es de 0,02 y la tasa de superposición es de un 80,8%; en conclusión

el método propuesto mejora el rendimiento de detección de objetos de tamaños pequeños.

Por su lado, respecto a los antecedentes a nivel nacional, Castañeda (2020) realizó un estudio con la finalidad de implementar un proceso de OCR que permite reconocer las matrículas de los vehículos, por lo cual creó data con imágenes de las matrículas rectificadas cuya finalidad era realizar la extracción correspondiente, a través del proceso de Filtración del ruido inicial de las imágenes con la finalidad de realizar una segmentación de la región de la placa con los caracteres correspondientes, para que posteriormente se procese cada dígito a través del OCR de forma individual, y encontró, al igual que investigaciones similares, que se logró conseguir una precisión del 89.33% del reconocimiento de las matrículas y 96.11% respecto a la identificación de los caracteres de forma individual.

Posteriormente, Castañeda (2022) encontró que, si uno desea la mejora del rendimiento de los clasificadores, era fundamental aumentar el porcentaje de entrenamiento, lo cual permitió crear una base que constaba de 32 modelos de vehículos haciendo uso de la red VGG16 para la extracción de determinadas especificaciones, como también, hicieron uso de los algoritmos de clasificación Máquinas de Vector Soporte (SVM), Bosques Akeatoris (RF), Árboles de Decisión (DT) y Naive Bayes (NB). En ese sentido, concluyeron que un 96.82% de precisión determinando para los 32 modelos, que conforme va incrementando la cantidad de muestreo vehicular que se quiere clasificar, es primordial incrementar, de igual forma, las muestras estabilizando la precisión.

Por otro lado, se realizó una investigación con la finalidad de comparar las redes neuronales convolucionales y el manejo de librerías virtuales, con el uso de la información extraída, de videograbaciones o imágenes en tiempo real, de vehículos de dos, tres y cuatro ruedas, encontraron que al comparar ambos métodos el proceso de detección, conteo y clasificación de vehículos haciendo uso de la Inteligencia Artificial, es un método apropiado que permite realizar el reemplazo de las capacidades de un ser humano en la obtención del aforo vehicular con una precisión del 95.60% del conteo y clasificación de los microbuses con inteligencia artificial, además de un 97.80% de precisión

de microbuses con el uso de visión artificial (Coanqui, Estofanero y Mamani, 2022).

Fernandez (2022) realizó una investigación para investigar autos con requisitoria, encontró que el sistema que creó incrementó el porcentaje de eficacia de un 64.41% a 86.79%, como también se percató del incremento del porcentaje de los vehículos con requisitoria (56.56% a 74.45%), por lo que su estudio permitió afirmar que sería muy útil que la Policía nacional del Perú utilice este patrón con inteligencia artificial debido a que ayuda a mejorar la detección de placas vehiculares.

Nizama (2022) propuso en su investigación otorgar una posible solución accesible, rentable y económica que logre encontrar un camino vehicular a través de los recursos que te brinda la inteligencia artificial, con lo cual logró clasificar determinados vehículos según su tipo en las redes porque tienen una serie de capas que permiten diferenciar un carácter del otro. Es así que se logró actualizar constantemente los modelos de tráfico utilizando cámaras de video, el modelo planteado se puede implementar como un recurso fundamental para el sistema de transporte inteligente. Se concluyó que la capacidad vehicular es fundamental para estudiar el tráfico vehicular, ya que a partir de ello se logra determinar el grado de ocupación y las condiciones en las que opera una vía, así como su futuro crecimiento.

En cuanto bases teóricas iniciamos con la variable independiente que es el algoritmo inteligente la cual es un tipo de algoritmo capaz de adquirir conocimiento y con respecto al aprendizaje del programa ocurre cuando su capacidad para abordar una tarea mejora a través de una colección de experiencias que al final con la experiencia acumulada, el desempeño progresa, lo que significa el viaje de aprendizaje (Fernando, 2020, párr. 5). Asimismo, el algoritmo es un método de una actividad, que se basa en un procedimiento o flujo de trabajo que se controla mediante comandos que el autor del algoritmo ya ha especificado (Vivar, 2018). También la inteligencia es una habilidad mental amplia que incluye la capacidad de razonar, planificar, resolver problemas, pensar de forma abstracta, comprender conceptos complicados, aprender rápidamente y aprender por experiencia (Sanz, 2018). Es decir, un algoritmo inteligente es un procedimiento que permite la

comprensión y el aprendizaje con el objetivo de resolver la cuestión que se le ha asignado bajo la supervisión de la persona que lo escribió antes.

Por otro lado, cuando se entrena utilizando redes neuronales convolucionales (CNN), el algoritmo inteligente aprende por sí mismo y tiene éxito con la extracción de características para el reconocimiento facial y/o el movimiento corporal del sujeto (Ameijeiras, González y Hernández, 2020).

En cuanto al reconocimiento de imágenes con el uso de la tecnología de aprendizaje profundo, el reconocimiento de imágenes emplea tecnologías y métodos para ayudar a los ordenadores a detectar, etiquetar y clasificar elementos de interés en una imagen, lo que da como resultado una identificación y categorización fiables de los objetos detectados en múltiples categorías especificadas (Shaip, 2022). Igualmente, la visión artificial comprende las técnicas de captura, tratamiento, análisis y comprensión de imágenes del mundo real con el fin de generar datos numéricos o simbólicos que pueda analizar un ordenador (Díaz, Gómez, Palacios y Sánchez, 2019). Gracias al uso de algoritmos AP, estas estrategias han experimentado una auténtica revolución en los últimos años. Asimismo, es crucial tener en cuenta el tiempo o lo que se tarda en identificar una foto; por lo tanto, cuantas más fotos se analicen, más difícil será que el algoritmo proporcione una respuesta a tiempo; por ello, existen enfoques basados en puntos distintivos e indicadores vitales.

De la misma manera, Deep Learning (DL) se ha transformado, llegando a abordar varios retos difíciles que han asolado a la comunidad de la IA durante mucho tiempo. En realidad, los modelos de aprendizaje profundo son variaciones más avanzadas de las redes neuronales artificiales (RNA) con numerosas capas, ya sean lineales o no lineales. Diferentes pesos enlazan cada capa con sus niveles inferior y superior. La capacidad de los modelos DL para aprender características jerárquicas a partir de múltiples formas de datos, como numéricos, imágenes, texto y audio, los hace eficaces para abordar problemas de reconocimiento, regresión, semi supervisados y no supervisados (Wang, Shao y Pourpanah, 2020), así mismo indican que un nuevo campo de estudio del aprendizaje automático (ML) es el aprendizaje profundo debido a que tiene varias capas de redes neuronales artificiales

ocultas en grandes conjuntos de datos. El enfoque del aprendizaje profundo emplea transformaciones no lineales y abstracciones de modelos de alto nivel. Las arquitecturas de aprendizaje profundo han hecho recientemente grandes avances en diversos dominios, y estos desarrollos ya han tenido un gran impacto en la inteligencia artificial (Vargas, Mosavi y Ruiz, 2018).

Al mismo tiempo el modelo más eficaz para clasificar imágenes es la red neuronal convolucional (CNN) la cual es un diseño particular de red neuronal artificial. Sus dos divisiones principales son las capas convolucionales y las capas completamente enlazadas. La base de la CNN es la capa convolucional, que aplica procesos de filtrado por convolución para extraer información de las imágenes (Ibtissam, Abdelmoghith, Wahban, Issam y Abdellaif, 2020). Sin embargo, las capas completamente enlazadas se encargan del componente de predicción. La parte de predicción la terminan una o varias capas interconectadas que se alimentan de las capas convolucionales al momento de culminar el proceso. Utilizando las características recuperadas de las capas anteriores, la CNN calcula la puntuación de cada clase. Las redes neuronales convolucionales exigen una gran cantidad de datos y recursos durante el entrenamiento, lo que las hace bastante costosas. Además, las CNN son redes neuronales profundas que utilizan capas convolucionales para filtrar las entradas en busca de información útil. Las capas convolucionales de las CNN calculan la salida de las neuronas vinculadas a partes específicas de la entrada aplicando filtros convolucionales a la entrada. Puede extraer características espaciales y temporales de las fotos (Hassan, Wang, Hussain y Fatima, 2021). Las CNN suelen tener tres capas: una capa convolucional para aprender características espaciales y temporales, una capa de agrupación para reducir o submuestrear la dimensionalidad de una imagen de entrada y una capa totalmente conectada (FC) para clasificar la imagen de entrada en clases distintas.

En términos de la definición de CNN, YOLO emplea su red neuronal convolucional patentada, DARKNET. DARKNET es un marco para el desarrollo y entrenamiento de redes neuronales convolucionales en problemas de visión por computadora. Este diseño también incluye 24 capas

convolucionales, que combinan categorización de imágenes e información sobre la ubicación y el tamaño de los objetos en la salida (Bagnato, 2020).




Figura 1: Arquitectura Darknet

Por otro lado, respecto a la variable dependiente, el Ministerio de Transportes y comunicación (MTC) (2018) decretó una norma legal, en el que modificó el Reglamento del Sistema de placa única nacional de rodaje, la cual especifica de manera puntual que la única placa de rodaje debe cumplir con la norma ISO 7591, DIN 74069 y/o ASTM E-810d.

Además, se utilizará la metodología ágil SCRUM, la cual es una técnica que brinda la flexibilidad para manejar proyectos complicados creados en situaciones dinámicas y en constante cambio. En función del valor que aportan a los clientes, se basa en la entrega periódica y parcial del producto terminado. En otras palabras, Scrum ayuda a los equipos a trabajar de forma más colaborativa. Es una práctica que ayuda a los equipos a aprender de sus errores y organizarse en consecuencia mientras resuelve problemas y fomenta la introspección tanto en los logros como en los fracasos. Todo esto está cubierto por una serie de herramientas y recursos que permiten a los equipos organizarse más rápidamente. Así mismo existen perfiles dentro de la metodología uno de ellos es el *Product Owner* (PO) que es el encargado de representar y expresar la voz del cliente durante todo el proceso, aumentando el valor del producto. El siguiente es el *Scrum Máster* (SM) que funciona como entrenador del Scrum Team, alentando e inspirando para completar el proyecto a tiempo. Además, ayudan al equipo fomentando un clima de cooperación para que se cumplan los objetivos del proyecto (Sáez, 2021). También para De Dios (2022) menciona que los equipos que gestionan proyectos con mucha imprevisibilidad utilizan un marco llamado Scrum.

Debido a que es un marco que permite a las personas abordar desafíos adaptativos difíciles mientras producen bienes con el mejor valor potencial de una manera productiva y creativa. Scrum es fácil de usar y comprender, pero difícil de dominar por completo. Este paradigma admite la entrega rápida de MVP (producto mínimo viable) y la velocidad de comercialización.

Además, la metodología SCRUM consta de 5 fases como se observa en la Figura para el correcto análisis del proyecto en desarrollo.



Figura 2: Las fases de metodología SCRUM

- **Sprint Planning:** Tiene la capacidad de especificar cómo se realizará la tarea es el componente más crucial de la etapa inicial de este método. En esencia, las responsabilidades se asignan a cada miembro del equipo en este punto y se establecen las fechas de entrega.
- **Scrum Team Meeting:** Se realiza una vez al día, estas sesiones rápidas se llevan a cabo para analizar las tareas que se han creado o se están creando, identificar problemas potenciales y abordar esos problemas.
- **Backlog Refinement:** El Backlog es una lista de trabajo realizada en orden de prioridad para el equipo. En esta fase se hace un repaso y un refinamiento de las tareas de cada uno.
- **Sprint Review:** Esta etapa consiste en revisar y analizar los resultados. Se organiza una reunión y el cliente suele asistir también. Durante la

reunión, todos trabajan juntos para determinar si es necesario realizar algún cambio.

- **Retrospective:** Es el último paso de la metodología. Esta es la última reunión en la que se aborda todo el proyecto. desde el principio hasta el final. El objetivo de esta fase es obtener toda la información necesaria para evitar repetir errores pasados en nuevas iniciativas.

Otra metodología que se usará es el CommonKads ya que es una de las más utilizada en los algoritmos de inteligencia, Giraldo y Montoya (2015) mencionan que la metodología CommonKads captura las características clave del sistema organizacional y su entorno a través de una variedad de modelos interconectados. Además de cubrir el ciclo completo de desarrollo de software, es una forma de crear sistemas basados en el conocimiento. CommonKads es un enfoque que incorpora principios de planificación estratégica, evaluación de proyectos y otros campos además del análisis de problemas y soluciones basadas en computadora, en la Figura se observa los modelos de la metodología CommonKads. A la misma vez Montoya y Giraldo (2015) refieren que los sistemas basados en conocimiento (SBC) pueden representar el conocimiento humano utilizando enfoques de inteligencia artificial, que permiten la preservación y el descubrimiento de nueva información para ayudar en su gestión. Su perspectiva organizacional enfatiza el análisis de problemas, el encontrar una posible alternativa de solución a problemáticas, determinar la toma de decisiones y el uso de conocimientos especializados en el área de aplicación determinada. Los SBC son responsables de reflejar el conocimiento de los expertos de una sucursal para utilizarlo en tareas de diagnóstico, capacitación y control.

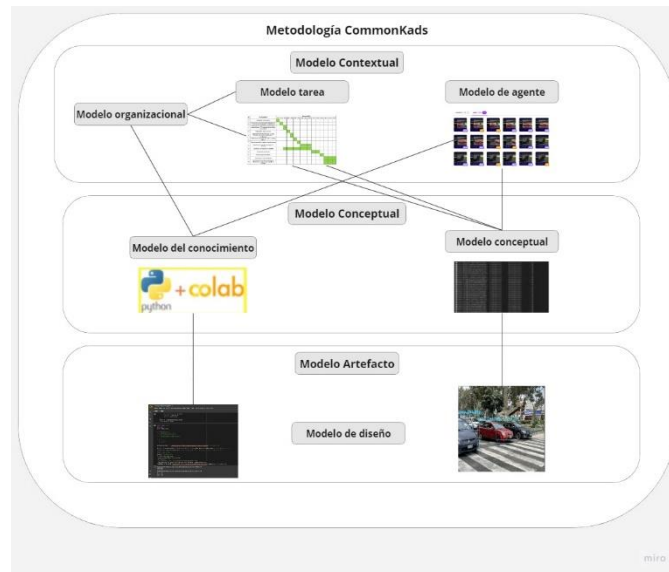


Figura 3: Metodología de construcción

En el nivel contextual, Harncharnchai y Saeheaw (2017) mencionan que es el lugar en el que se concentra el análisis de la organización con el fin de definir sus dificultades y ventajas. El modelo de organización (OM) será el componente principal de este nivel. Las tareas de los procesos también se examinarán en el modelo de tareas (TM) tomando en consideración los ingresos, salidas y condiciones previas, además de factores adicionales. El modelo de agente (MA) se encargará de examinar sus características y las interacciones inter-agente, ya sean estos agentes sistemas o personas.

A nivel conceptual Harncharnchai y Saeheaw (2017) señalan que determinadas explicaciones del conocimiento necesario para actividades e interacciones de los agentes. El modelo de conocimiento (EM), que conforman este nivel, ayudará a comprender las variedades y patrones organizativos del conocimiento de cada tarea. El modelo de comunicación (CM), que simulará la comunicación de los distintos agentes que intervienen en las tareas, será el último paso.

Respecto al nivel de artefacto Harncharnchai y Saeheaw (2017) es una etapa de diseño de un sistema conectado al modelo conceptual y realizado haciendo uso de un lenguaje de codificación específico. Asimismo, incluirá el modelo de diseño y los requisitos técnicos que permitan implementar un sistema, como la arquitectura y el mecanismo.




Figura 4: Modelos de metodología CommonKads

III. METODOLOGÍA

3.1 Tipo y diseño de investigación

3.1.1 Tipo de investigación:

Este estudio será de tipo aplicada, el cual la página DuocUC (2023) propone que tiene como objetivo utilizar el conocimiento de uno o más campos especializados con el fin de implementarlo de manera práctica para satisfacer demandas particulares, ofreciendo una solución a problemas en el sector social o productivo. Este énfasis está en abordar los problemas en un contexto específico. Como indica la página, emplearemos el tipo aplicado en este estudio ya que proporcionaremos una solución práctica basada en información teórica relacionada con el reconocimiento de imágenes.

Debido a que se cree que el reconocimiento de vehiculares debe ser objetiva y que ésta resulta de un proceso lógico, y estará enfocado de forma cuantitativa, el cual Artega (2020) menciona que se concentran en mediciones precisas y análisis estadístico, matemático o numérico de la información recopilada a través de cuestionarios, encuestas y otras formas de recopilación de datos, o mediante el empleo de métodos informáticos para modificar la información estadística ya existente. Los principales objetivos de la investigación cuantitativa son recopilar y generalizar datos numéricos entre poblaciones o comprender un hecho específico.

3.1.2 Diseño de investigación

El diseño del presente estudio será pre-experimental, donde Bastis (2022) propone que es un diseño de estudio donde se utilizan ciertas características experimentales fundamentales, pero otras no. Debido a esto, un experimento no es genuinamente experimental. Este tipo de diseño a menudo se usa para realizar investigaciones exploratorias a un costo razonable para ver si hay suficientes datos para respaldar una investigación experimental a gran escala.




Figura 5: Diseño Pre-Experimental

En el cual:

G: Grupo experimental.

X: Variable independiente – Algoritmo inteligente.

O: Evaluación de la clasificación de vehículo y la extracción de caracteres de las placas vehiculares luego de la ejecución del algoritmo inteligente.

3.2 Variable y Operacionalización

- **Variable Independiente:** Algoritmo inteligente
 - **Definición Conceptual:** El algoritmo inteligente es una herramienta que permite analizar imágenes en tiempo real, facilitando el trabajo de los equipos de seguridad a través de alertas sobre posibles sucesos peligrosos que requieran alguna investigación.
- **Variable Dependiente:** Reconocimiento de vehículos y sus matrículas
 - **Definición Conceptual:**
 - **Clasificación de vehículos:** La clasificación vehicular es la categorización que se realiza según ciertas características, como el peso, capacidad, tipo y uso del medio de transporte, según el lugar de procedencia. (Tarazona, 2018; Zoilo Ríos, S.A. 2021).
 - **Extracción de caracteres:** La extracción de caracteres de una imagen se refiere al proceso de identificar y aislar caracteres o texto contenido en una imagen digital para su posterior procesamiento, análisis o conversión en texto legible por una computadora. Esto es comúnmente realizado mediante técnicas de reconocimiento óptico de caracteres (OCR, por sus siglas en inglés), que utilizan algoritmos y software especializado para detectar letras, números y otros caracteres en una imagen y convertirlos en texto digital. (Ostrovskij, 2023).

- **Definición Operacional:** Las placas vehiculares se medirán a través de la detección de imágenes mediante la precisión, sensibilidad, F1 Score y precisión de reconocimiento de caracteres.
- **Dimensiones:**
 - **Clasificación:** Es una herramienta que permite agrupar en relación con el modelo del vehículo, el cual se divide en placas ordinarias considerados vehículos que circulan por la vía pública terrestre y placas especiales, que son aquellos vehículos que tienen como finalidad una actividad colectiva como también el resguardo de orden público (Asociación Automotriz del Perú, 2023).
 - **Extracción de caracteres:** Es una herramienta crucial para la transformación digital, ya que automatiza la recopilación y el procesamiento de datos, aumentando la precisión y la eficiencia en una variedad de aplicaciones. OCR (Reconocimiento Óptico de Caracteres, por decirlo en español) es una técnica que funciona con esta herramienta para extraer texto de documentos impresos o escritos a mano y convertirlo en documentos digitales editables.
- **Indicadores:**

Se realizó una métrica a través del uso de RECALL, el cual Gómez y Castrillón (2019) proponen que mide el desempeño de un sistema al intentar identificar objetos en función a su propósito. También permite calcular de qué manera la relación entre el número de positivos correctamente clasificados como positivos (TP), como también la cifra final del muestreo positivo (TP), además de la cantidad de objetos de la clase detectados que no pertenecen a la clase (FN).

$$r = \frac{TP}{TP + FN}$$

Figura 6: Fórmula de RECALL (Leite et al. 2022)

Asimismo, se emplea la PRECISIÓN y los autores Gómez y Castrillón (2019) explican que, que cuenta la proporción de pronósticos positivos que se cumplen. De tal manera que Vakili, Ghamsari, y Razaie (2020)

indican que es la más demandada entre el conjunto de métricas existentes porque evalúa el desempeño del algoritmo en problemas de clasificación y define la relación entre elementos de datos clasificados con precisión y verdad. positivos (PT) y falsos positivos (FP), o el número de objetos que no se detectaron como objetos.

$$p = \frac{TP}{TP + FP}$$

Figura 7: Fórmula de PRECISIÓN (Leite et al. 2022)

Finalmente, la métrica F1 SCORE, que según los autores Gómes y Castrillón (2019) también se conoce como fórmula de Sorensen-Dice, se utiliza para evaluar los sistemas de clasificación, que se clasifican en positivos o negativos, y se refiere a una medida armónica. del equilibrio entre precisión y sensibilidad. Idealmente, debería establecerse en 1.

$$f1 = 2 * \frac{(PRECISION * RECALL)}{PRECISION + RECALL}$$

Figura 8: Fórmula de F1 SCORE (Leite et al. 2022)

Finalmente, la métrica de precisión del reconocimiento de caracteres denota la capacidad del sistema para convertir con precisión caracteres impresos o escritos a mano en texto digital. Generalmente expresado como porcentaje, significa la proporción de caracteres identificados correctamente con respecto al número total de caracteres procesados. Una precisión de caracteres alta sugiere que la mayoría, si no todos, los caracteres se reconocen con precisión, mientras que una precisión baja indica una mayor aparición de errores durante la conversión de caracteres (Shim, et al. 2022)

$$RA = \frac{\text{número total de reconocimientos correctos de caracteres}}{\text{número total de caracteres alfanuméricos}} * 100$$

Figura 9: Fórmula de precisión de reconocimiento (Shim et al. 2022)

3.3 Población, muestra y unidad de análisis

Población

Zamora (2022) define la población como el número total de individuos que contribuyen al fenómeno bajo consideración. La población de este estudio está formada por 2.500 imágenes de automóviles tomadas por los propios investigadores en las calles más transitadas de Lima. Además, se aplicaron criterios particulares de inclusión y exclusión a las fotografías obtenidas.

Tabla 1: *Población de la investigación*

Población	Cantidad
Fotografías de vehículos	2500

Fuente: elaboración propia

- **Criterios de inclusión:** Se incorporarán imágenes claras con la iluminación adecuada.
- **Criterios de exclusión:** Las imágenes capturadas en movimiento, muy distorsionadas o en condiciones de poca iluminación no son elegibles para su inclusión.

Muestra

Según Zapata (2020) menciona que el grupo de elementos seleccionados para reflejar la población como un todo es lo que se entiende por el término "muestra". Como indicamos, esto se está haciendo para facilitar la tarea y la gestión de reducción en datos de recursos y una finalización más rápida del trabajo. La muestra para este estudio se elegirá de acuerdo con los objetivos de la investigación, como se muestra en la Tabla 2. Además, el estudio incluyó todas las fotografías de la población.

Tabla 2: *Muestra de investigación*

	Train	Valid	Test
Vehículos	80%	10%	10%

Fuente: elaboración propia

Unidad de análisis

El presente estudio contará con una muestra integrada de 30 fotografías de vehículos de distintos ángulos.

3.4 Técnicas e Instrumentos de recolección de datos

La página SafetyCulture (2023) menciona que la técnica de la observación es simplemente ver los comportamientos o actividades de un sujeto en un entorno particular para comprenderlos y documentar lo que se ve es el tipo de observación más típico en el contexto de la recopilación de datos (pp.5). Como técnica, la observación se emplea en la investigación actual, ya que es apropiada para nuestra indagación y también es constantemente utilizada para otras investigaciones similares a esta en donde trabajan esta temática.

Además, se usará el instrumento de ficha de observación y según Arias (2021) refiere que este instrumento permite ser utilizado en investigaciones experimentales y no experimentales para examinar e identificar los elementos del elemento evaluado, incluidas sus características, funcionamiento y comportamiento (p.55).

Tabla 3: *Técnicas e instrumento para cada indicador*

Indicadores	Técnicas	Instrumento
Precisión	Observación	Ficha de registro
Recall	Observación	Ficha de registro
F1-Score	Observación	Ficha de registro
Precisión de reconocimiento de caracteres	Observación	Ficha de registro

3.5 Procedimientos




Figura 10: Flujograma del procedimiento del proyecto

El procedimiento de la investigación inicia con el desarrollo de la tesis, utilizando la ficha de registro para recolectar la data, la ficha de registro de observación, además se procederá a recolectar las imágenes necesarias para el desarrollo del algoritmo que usará el método YOLO y debidamente se realizarán constantes entrenamientos al algoritmo, una vez concluido, los entrenamientos se realizarán pruebas de satisfacción para conseguir los datos del Post-Test que se requieren para un análisis de datos estadístico y asimismo dar las conclusiones y discusiones de los resultados obtenidos.

La técnica CommonKads se utilizará en este estudio como método ya que tiene beneficios como una estrategia de desarrollo de modelos que se puede ver desde varios ángulos. Es importante porque ofrece un marco para la definición de conocimiento que es independiente de la implementación. El procedimiento constó de las siguientes fases:

- **Definir el conjunto de imágenes:** Se recopilará 2500 imágenes de vehículos en este sentido de las clases (taxis, autos privados, bus y camión de carga), luego serán clasificadas y etiquetadas con la ayuda de la herramienta Roboflow. El conjunto de datos facilita que el algoritmo pase por un proceso de entrenamiento, por lo que se realizó

la división en dos partes: 80 % para entrenamiento de imágenes, 10% para testeo y 10 % para validación.

- **Redimensionado de Imágenes y Limpieza:** Las fotos que han sido redimensionadas y anotadas se colocarán en Google Colab para el entrenamiento de redes neuronales convolucionales e inteligencia artificial. Se utilizaron Tensor Flow, Yolo v4 y EasyOCR para completar este proceso. En cuanto a la limpieza de imágenes, utilizamos fotos de alta calidad que podrían usarse para distinguir las placas de los vehículos.
- **Entrenamiento y Validación:** Gracias al modelo creado después de una capacitación y validación anteriores, se realizaron las pruebas y la detección de los indicadores de investigación: Precisión, Puntuación F1, Sensibilidad y precisión de reconocimiento de caracteres. Para realizar las pruebas se construirá un proyecto utilizando Jupiter Notebook, Python 3.10, Yolo V4, las librerías necesarias y las etapas ya realizadas.
- **Recolección de imágenes y Detección:** Se recopilan imágenes de vehículos. Tras la detección de las imágenes posteriormente a la recolección de verdaderos positivos (VP), falsos negativos (FN), verdaderos negativos (TN) y falsos positivos (FP), podemos realizar las métricas indicadas, incluyendo su precisión, sensibilidad, puntuación f1 y precisión de reconcomiendo de caracteres para las dimensiones de extracción y clasificación.




Figura 11: Metodología de construcción

3.6 Método de análisis de datos

La investigación se realizó tomando como recurso un software IBM SPSS para examinar los datos recopilados en la ficha de registro en relación con los indicadores especificados, tales como: Precisión, Puntuación F1 y Sensibilidad. Previamente se empleaba la estadística descriptiva. Se utilizarán tablas y gráficos para ilustrar los datos finales que se han recopilado.

Con relación a la determinación de la normalidad de la data, se propuso el siguiente criterio:

$p < 0.05$ se considera que la data no sigue una distribución normal

$p \Rightarrow 0.05$ se consideró que la data sigue una distribución normal

Hipótesis General:

Hipótesis Alternativa (Ha): El algoritmo inteligente clasificó los vehículos y extrajo los caracteres de sus matrículas

Hipótesis Nula (H0): El algoritmo inteligente no clasificó los vehículos y no extrajo los caracteres de sus matrículas.

Hipótesis Específica 1:

Hipótesis Alternativa (Ha): El algoritmo inteligente logra clasificar los vehículos.

Hipótesis Nula (H0): El algoritmo inteligente no logra clasificar los vehículos.

Hipótesis Específica 2:

Hipótesis Alternativa (Ha): El algoritmo inteligente logra detectar las placas.

Hipótesis Nula (H0): El algoritmo inteligente no logra detectar las placas.

Hipótesis Específica 3:

Hipótesis Alternativa (Ha): El algoritmo inteligente logra extraer los caracteres de las placas vehiculares.

Hipótesis Nula (H0): El algoritmo inteligente no logra extraer los caracteres de las placas vehiculares.

3.7 Aspectos éticos

El crecimiento de este estudio seguirá lineamientos éticos, garantizando la validez de los hallazgos y promoviendo en gran medida el avance de la presente investigación. Adicionalmente, se tomó en cuenta la precisión de la veracidad de la investigación, y se realizó un adecuado uso del manual ISO 690 y 690-2 y el artículo 13° de la naturaleza y designación de sus miembros según el comité de ética de investigación que forman parte de la editorial de la Universidad César Vallejo. Además, el servicio Turniting, el cual sirvió de apoyo para la prevención del plagio que es un porcentaje mínimo de 20%.

IV. RESULTADOS

Análisis Descriptivo

Tabla 4: Cuadro estadístico del indicador de precisión

Estadísticos descriptivos						
	N	Mínimo	Máximo	Media	Desviación estándar	Varianza
presicion-pre	30	,00	,33	,1700	,11736	,014
presicion-post	30	,00	1,00	,6233	,24271	,059

Fuente: elaboración propia

La tabla 4 ilustra claramente una mejora significativa en la precisión. Antes de la prueba, el valor mínimo llegó a tener un valor de 0,00 y el valor máximo un 0,33 (33%), pero luego de las pruebas el valor mínimo no se movió y el valor máximo aumento a un 1,00 (100%). Además, la precisión media se situaba en 0,17 (17%), pero ahora ha aumentado hasta 0,62 (63%) en los resultados posteriores a la prueba. Asimismo, se observa que la varianza de la precisión tuvo un aumento del 0,14 (14%) al 0,59 (59%)

Tabla 5. Cuadro estadístico del indicador de recall

Estadísticos descriptivos						
	N	Mínimo	Máximo	Media	Desviación estándar	Varianza
recall-pre	30	,00	,33	,1897	,11081	,012
recall-post	30	,17	1,00	,6467	,22143	,049

Fuente: elaboración propia

La tabla 5 ilustra claramente una mejora significativa en la precisión. Antes de la prueba, el valor mínimo llegó a tener un valor de 0,00 y el valor máximo un 0,33 (33%), pero luego de las pruebas el valor mínimo no se movió y el valor máximo aumento a un 1,00 (100%). Además, la precisión media se situaba en 0,18 (18%), pero ahora ha aumentado hasta 0,64 (64%) en los resultados posteriores a la prueba. Asimismo, se observa que la varianza de la precisión tuvo un aumento del 0,12 (12%) al 0,49 (49%).

Tabla 6. Cuadro estadístico del indicador de F1score

Estadísticos descriptivos						
	N	Mínimo	Máximo	Media	Desviación estándar	Varianza
f1score-pre	30	,00	,33	,1893	,12390	,015
f1score-post	30	,00	1,00	,6023	,24278	,059

Fuente: elaboración propia

La tabla 6 ilustra claramente una mejora significativa en la puntuación f1. Antes de la prueba, el valor mínimo llegó a tener un valor de 0,00 y el valor máximo un 0,33 (33%), pero luego de las pruebas el valor mínimo no se movió y el valor máximo aumentó a un 1,00 (100%). Además, la precisión media se situaba en 0,19 (19%), pero ahora ha aumentado hasta 0,60 (60%) en los resultados posteriores a la prueba. Asimismo, se observa que la varianza de la puntuación f1 tuvo un aumento del 0,15 (15%) al 0,59 (59%).

Tabla 7. Cuadro estadístico del indicador de Precisión de reconocimiento de caracteres.

Estadísticos descriptivos						
	N	Mínimo	Máximo	Media	Desviación estándar	Varianza
reconocmientocaracteres-pre	30	,00	,80	,1180	,20478	,042
reconocmientocaracteres-post	30	,33	1,00	,6137	,18596	,035

Fuente: elaboración propia

La tabla 7 ilustra claramente una mejora significativa en la precisión. Antes de la prueba, el valor mínimo llegó a tener un valor de 0,00 y el valor máximo un 0,80 (80%), pero luego de las pruebas el valor mínimo no se movió y el valor máximo aumentó a un 1,00 (100%). Además, la precisión media se situaba en 0,12 (12%), pero ahora ha aumentado hasta 0,61 (61%) en los resultados posteriores a la prueba. Asimismo, se observa que la varianza de la precisión tuvo un aumento del 0,04 (4%) al 0,03 (3%).

Indicador 1. PCV: Precisión para la clasificación de vehículos

La tabla 8 muestra los resultados de las estadísticas descriptivas para PCV.

Tabla 8. Medidas descriptivas de PCV: Precisión para la clasificación de vehículos

Estadísticos		
presicion-post		
N	Válido	30
	Perdidos	0
Media		,6233

Fuente: elaboración propia

El indicador PCV, que mide la precisión de la clasificación de vehículos, mostró una precisión promedio de 0,62 en la prueba posterior, lo que indica un nivel promedio de precisión del 62%.

Indicador 2. RCV: Recall para la clasificación de vehículos

La tabla 9 muestra los resultados de las estadísticas descriptivas para RCV.

Tabla 9. Medidas descriptivas de RCV: Recall para la clasificación de vehículos

Estadísticos		
recall-post		
N	Válido	30
	Perdidos	0
Media		,6467

Fuente: elaboración propia

El indicador RCV, que mide el recall de la clasificación de vehículos, mostró una precisión promedio de 0,64 en la prueba posterior, lo que indica un nivel promedio de precisión del 64%.

Indicador 3. FCV: F1 score para la clasificación de vehículos

La tabla 10 muestra los resultados de las estadísticas descriptivas para FCV.

Tabla 10. Medidas descriptivas de FCV: F1score para la clasificación de vehículos

Estadísticos		
f1score-post		
N	Válido	30
	Perdidos	0
Media		,6023

Fuente: elaboración propia

El indicador FCV, que mide el F1 score de la clasificación de vehículos, mostró una precisión promedio de 0,60 en la prueba posterior, lo que indica un nivel promedio de f1 score del 60%.

Indicador 4. PRC: Precisión de reconocimiento de caracteres

La tabla 11 muestra los resultados de las estadísticas descriptivas para FCV.

Tabla 11. Medidas descriptivas de PRC: Precisión de reconocimiento de caracteres de las placas vehiculares

Estadísticos		
reconocmientocaracteres-post		
N	Válido	30
	Perdidos	0
Media		,6137

Fuente: elaboración propia

El indicador PRC, que mide la precisión del reconocimiento de los caracteres de las placas vehiculares, mostró una precisión promedio de 0,61 en la prueba posterior, lo que indica un nivel promedio de precisión de reconocimiento de caracteres del 61%.

Para resumir efectivamente los valores de los indicadores antes mencionados, la tabla 12 proporciona una representación condensada de los indicadores.

Tabla 12. Resumen de Indicadores

	Indicadores			
	PCV	RCV	FCV	PRC
Valor	0,62	0,64	0,60	0,61

La tabla 12 revela una descripción general completa de todos los indicadores aplicados para evaluar las clasificaciones y extracciones dentro de las fotografías probados utilizando nuestro algoritmo desarrollado. En particular, destaca una impresionante puntuación de Recall promedio del 54%, lo que significa el sólido rendimiento del algoritmo, con margen de mejora potencial en el futuro.

Prueba de Hipótesis

Para obtener la distribución de los datos, se ejecutará esta prueba de normalidad. Para evaluar la normalidad, se proponen las siguientes teorías.

H_0 = Los datos siguen una distribución normal

H_a = Los datos no siguen una distribución normal

Nivel de significancia:

Confianza: 95%

Significancia (ALFA): 5%

Decisión:

- Si $p \leq 0.05$, se rechaza la H_0 y se acepta la H_a , por lo tanto, se utiliza una prueba no paramétrica.
- Si $p > 0.05$, se acepta la H_0 y se rechaza la H_a , por lo tanto, se utiliza una prueba paramétrica

Tabla 13. Tabla de indicadores de las hipótesis estadísticas

INDICADOR 1	PCV: Precisión para la clasificación de vehículos
INDICADOR 2	RCV: Recall para la clasificación de vehículos
INDICADOR 3	FCV: F1 score para la clasificación de vehículos
INDICADOR 4	PRC: Precisión de reconocimiento de caracteres

Tabla 14. Tabla de pruebas de normalidad del indicador de precisión

Pruebas de normalidad						
	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
precision-pre	,186	30	,010	,900	30	,008
precision-post	,139	30	,144	,961	30	,331

a. Corrección de significación de Lilliefors

Fuente: elaboración propia

Como se indica en la Tabla 14, el p-valor del indicador de precisión son 0,008 y 0,331, lo que significa valores inferiores a α . Esto sugiere que los datos siguen una distribución normal.

Tabla 15. Tabla de pruebas de normalidad del indicador de recall

Pruebas de normalidad						
	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
recall-pre	,207	30	,002	,854	30	,001
recall-post	,121	30	,200*	,952	30	,194

a. Corrección de significación de Lilliefors

Fuente: elaboración propia

Como se indica en la Tabla 15, el p-valor del indicador de precisión son 0,001 y 0,194, lo que significa valor superior a α . Esto sugiere que los datos siguen una distribución normal.

Tabla 16. Tabla de pruebas de normalidad del indicador de f1score

Pruebas de normalidad						
	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
f1score-pre	,188	30	,009	,864	30	,001
f1score-post	,103	30	,200*	,972	30	,602
a. Corrección de significación de Lilliefors						

Fuente: elaboración propia

Como se indica en la Tabla 16, el p-valor del indicador de precisión son 0,001 y 0,602, lo que significa valores inferiores a α . Esto sugiere que los datos siguen una distribución normal.

Tabla 17. Tabla de pruebas de normalidad del indicador de Precisión de reconocimiento de caracteres

Pruebas de normalidad						
	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
reconocmientocaracteres-pre	,318	30	,000	,639	30	,000
reconocmientocaracteres-post	,196	30	,005	,914	30	,019
a. Corrección de significación de Lilliefors						

Fuente: elaboración propia

Como se indica en la Tabla 17, el p-valor del indicador de precisión son 0,000 y 0,019, lo que significa valores inferiores a α . Esto sugiere que los datos no siguen una distribución normal.

En resumen, las pruebas de normalización demuestran que 3 de los indicadores siguen una distribución normal y 1 de ellos no siguió una distribución normal, pero como todos los indicadores nos cumplen con los

requerimientos. En consecuencia, utilizaremos la prueba de rangos de Wilcoxon para los indicadores de distribución no normal. Esta prueba nos permite decidir si rechazar la hipótesis nula y aceptar la hipótesis alternativa si el valor p es menor o igual a α (0,05), o aceptar la hipótesis nula si el valor p es mayor que α .

Tabla 18. Tabla de rango de wilcoxon del indicador de precisión

Estadísticos de prueba^a	
	presicion- post - presicion- pre
Z	-4,626 ^b
Sig. asintótica (bilateral)	,000
a. Prueba de Wilcoxon de los rangos con signo	
b. Se basa en rangos negativos.	

Fuente: elaboración propia

Se evidencia en la Tabla 18, que el valor de p es 0, lo que significa que es menor que α (0,05). En consecuencia, esto sugiere que se rechaza la hipótesis nula a favor de la hipótesis alternativa.

Tabla 19. Tabla de rango de wilcoxon del indicador de recall

Estadísticos de prueba^a	
	recall-post - recall-pre
Z	-4,627 ^b
Sig. asintótica (bilateral)	,000
a. Prueba de Wilcoxon de los rangos con signo	
b. Se basa en rangos negativos.	

Fuente: elaboración propia

Como se señala en la Tabla 19, el valor p es 0,000 lo que significa que es menor que α (0,05). En consecuencia, esto sugiere se acepta la hipótesis alternativa, rechazando la hipótesis nula.

Tabla 20. Tabla de rango de wilcoxon del indicador de f1score

Estadísticos de prueba^a	
	f1score-post - f1score- pre
Z	-4,639 ^b
Sig. asintótica (bilateral)	,000
a. Prueba de Wilcoxon de los rangos con signo	
b. Se basa en rangos negativos.	

Fuente: Elaboración propia

Como se indica en la Tabla 20, el valor p es 0,000, lo que significa que es menor que α (0,05). En consecuencia, esto sugiere el rechazo de la hipótesis nula a favor de la hipótesis alternativa.

Tabla 21. Tabla de rango de wilcoxon del indicador de precisión de reconocimiento de caracteres

Estadísticos de prueba^a	
	reconocmie ntocaractere s-post - reconocmie ntocaractere s-pre
Z	-4,791 ^b
Sig. asintótica (bilateral)	,000
a. Prueba de Wilcoxon de los rangos con signo	
b. Se basa en rangos negativos.	

Fuente: Elaboración propia

Como se indica en la Tabla 21, el valor p es 0,000, lo que significa que es menor que α (0,05). En consecuencia, esto sugiere el rechazo de la hipótesis nula a favor de la hipótesis alternativa.

Al observar las tablas de rangos de Wilcoxon los valores de p para todos los indicadores son menores que (0,05). Como resultado, se rechaza la hipótesis nula y se acepta la hipótesis alternativa.

V. DISCUSIÓN

El objetivo principal de esta investigación fue desarrollar un algoritmo inteligente para clasificar automóviles y extraer caracteres de las matrículas. Se reveló que la métrica de Precisión mostró una precisión del 62% al clasificar las 30 fotografías de automóviles. Para abordar esto, el estudio tuvo como objetivo diseñar un modelo híbrido para la clasificación de vehículos, combinando un modelo de selección de características evolutivas con una red neuronal convolucional (CNN) previamente entrenada, lograron una notable tasa de precisión del 99,7 % en la clasificación de vehículos, Ahmed, et al (2023). En comparación, nuestra investigación mostró una discrepancia del 37,7% con respecto a esta cifra. Además, Lai et al. (2022) obtuvieron una tasa de precisión del 92 % en la clasificación de vehículos mediante el uso del algoritmo de aprendizaje delta para identificar y clasificar automóviles mientras eliminaban sus contrapartes en la sombra. En consecuencia, nuestra investigación arrojó un 30% menos de precisión en comparación con el estudio inicial. Asimismo, un estudio que utilizó la tecnología YOLOv4 para construir un sistema integrado para reconocer varios tipos de vehículos y matrículas logró una precisión del 87 % en la categorización de vehículos (Kim, et al., 2022). En consecuencia, nuestra investigación demostró una discrepancia del 25% en la precisión en comparación con estos otros estudios.

El indicador de sensibilidad para la clasificación de vehículos fue del 64% basándose en 30 imágenes de automóviles. Kim, et al. (2022) emplearon la tecnología YOLOv4 para crear un sistema para identificar tipos de vehículos y matrículas, logrando una sensibilidad del 94%. En consecuencia, nuestra investigación mostró un 30% menos de sensibilidad en comparación con la de ellos. Además, Hasan et al. (2021) se propusieron construir un modelo utilizando aprendizaje por transferencia y aumento de datos, alcanzando una sensibilidad del 98% en la clasificación de vehículos. Por lo tanto, nuestra investigación tuvo menos respuesta en aproximadamente un 34% en comparación con el trabajo de Hasan et al.

En la misma línea, nuestra investigación logró un resultado del 60% utilizando la puntuación F1 como indicador para la clasificación de vehículos, basándose en 30 fotografías de automóviles. Kim, et al (2022) utilizaron la tecnología

YOLOv4 y desarrollaron un sistema integral para identificar varios vehículos y matrículas, logrando una puntuación de F1score del 90 % en la clasificación de vehículos. En consecuencia, nuestro estudio mostró un 30% menor en comparación con el de ellos. La investigación de Hasan, et al (2021) establecieron un modelo basado en el aprendizaje por transferencia con aumento de datos, clasificando con éxito vehículos con una puntuación de F1 del 98%. Por lo tanto, nuestra investigación demostró una puntuación F1 inferior al 38% en comparación con estos estudios de referencia.

Tras una prueba de 30 fotografías de automóviles, se encontró que la precisión del reconocimiento de caracteres, más precisa era del 61%. El uso del método K-nearest en su sistema de procesamiento de imágenes para la identificación y el reconocimiento de matrículas produjo una asombrosa precisión de reconocimiento de caracteres del 96% en una investigación realizada por Praveen et al. (2020). Como resultado, nuestro análisis reveló una precisión de reconocimiento de caracteres un 35% inferior que la de ellos. Además, el estudio realizado por Mohammad et al. (2023) dieron a conocer un sistema rentable de Internet de las cosas diseñado para estacionamientos inteligentes, con una tasa de precisión del 93% en el reconocimiento de caracteres. Como resultado, la precisión del reconocimiento de caracteres de nuestra investigación fue un 32% menor que la del estudio citado.

VI. CONCLUSIONES

- 1) En términos de identificación de automóviles y matrículas, el método inteligente de clasificación y extracción tuvo una precisión promedio del 62%, una sensibilidad del 64%, una puntuación F1 del 60% y un reconocimiento de caracteres del 61%.
- 2) Los resultados de las pruebas indican que el algoritmo detecta automóviles de manera eficiente y extrae caracteres de las matrículas. Con base en el estudio realizado en el software SPSS utilizando el enfoque de Wilcoxon para todos los indicadores, se rechaza la hipótesis nula.
- 3) También se muestra que los dos algoritmos se fusionaron sin esfuerzo y sin conflictos en sus respectivos porcentajes de medida. Lograron buenos resultados a pesar de limitaciones como las diferencias de contraste de la imagen, la iluminación, los ángulos de los vehículos en las imágenes y los recursos limitados del equipo.
- 4) Si bien la investigación produjo resultados alentadores, todavía quedan algunas preguntas sin respuesta. Dado que el algoritmo necesita aprender cosas nuevas constantemente, un problema importante es recopilar una gran cantidad de fotografías para cada clase. Por otro lado, en un entorno social, la extracción y categorización de vehículos mejoraría enormemente el seguimiento del tráfico y el mantenimiento de registros de peajes, lo que aumentaría la eficiencia general.
- 5) El estudio indica que la biblioteca más buscada para la extracción de caracteres en el motor OCR es EasyOCR. Esta decisión está respaldada por su mayor facilidad de uso y eficacia en el reconocimiento de matrículas teniendo en cuenta los ángulos y distancias de los automóviles. Además, mejora la precisión de la identificación de caracteres en las matrículas de automóviles, añadiendo valor.

VII. RECOMENDACIONES

- Se recomienda que futuros intentos de investigación investiguen las relaciones con otros factores, especialmente aquellos que puedan ser relevantes para los dominios estudiados en este trabajo, como la detección de rostros.
- Además, se pueden obtener conocimientos útiles reproduciendo la técnica del algoritmo inteligente para la extracción de caracteres y la categorización de vehículos en una gama más amplia de clases y poblaciones. En diferentes niveles, como sectores individuales dentro de un distrito, instituciones estatales, ciudades o incluso a nivel macro, permitiendo comparaciones entre países, esta replicación puede ser muy útil. Estas comparaciones a gran escala serían informativas ya que muchos factores podrían tener un impacto sustancial en los resultados.
- Para mejorar la velocidad, eficacia y eficiencia en sus operaciones, también se recomienda utilizar algoritmos similares a los sistemas que monitorean el tráfico, la delincuencia y el estacionamiento.
- Se recomienda que las comunidades que deseen poner en práctica estos avances realicen una investigación exhaustiva de diversas tecnologías para la identificación y categorización de objetos.
- Finalmente, se recomienda incluir más fotografías en la investigación para aumentar la confiabilidad de los resultados y promover tanto la calidad como la variedad de los resultados.

REFERENCIAS

- AGUILAR, Juan. Prototipo de reconocimiento de placas vehiculares para la detección de vehículos alertados en el complejo de control aduanero de Tomasiri, Tacna - 2022. Tesis (Ingeniería de Sistemas). Tacna: Universidad de Tacna, 2022. Disponible en: <http://161.132.207.135/bitstream/handle/20.500.12969/2429/Aguilar-Anaya-Juan.pdf?sequence=1&isAllowed=y>
- AGUIRRE, Juan. Robo de vehículos en México. Cuadernos de investigación No. 45. México: Instituto Belisario Domínguez, Senado de la República, 2018. Disponible en: <http://bibliodigitalibd.senado.gob.mx/bitstream/handle/123456789/4055/Robo%20de%20Veh%C3%ADculos%20en%20M%C3%A9xico.pdf>
- AMEIJEIRAS, David, GONZÁLEZ, Héctor, HERNÁNDEZ, Yanio Algorithms for detection and tracking objects with deep networks for intelligent video surveillance: A review. Ciencias informáticas [en línea]. 25 de junio de 2020,14(3), 165-195. [Fecha de consulta: 11 de mayo de 2023]. Disponible en: <https://www.redalyc.org/journal/3783/378365834009/html/#B38>
- An automated license plate detection and recognition system based on wavelet decomposition and CNN por Slimani, Ibtissam [et all], [en línea]. diciembre 2020, 8, 100040. [Fecha de consulta: 5 de mayo de 2023]. Disponible en: <https://doi.org/10.1016/j.array.2020.100040>
ISSN:2590-0056
- Applications of Artificial Intelligence in Cardiology. The Future is Already Here por DORADO, P. [et all], [en línea]. diciembre 2019, 72(12), 1065-1075. [Fecha de consulta: 10 de mayo de 2023]. Disponible en: <https://www.sciencedirect.com/science/article/abs/pii/S0300893219302507>
- Arias-Gonzales, J. (2021). Proyecto de Tesis guía para la elaboración. <https://www.researchgate.net/publication/350072280>
- Asociación Automotriz del Perú (AAP). (2023). Nueva Placa Única Nacional de Rodaje. En: Asociación Automotriz del Perú [en línea]. Disponible en: <https://aap.org.pe/placas/tipos/>
- CASTAÑEDA, Carlos. Estudio sobre la cantidad mínima de muestras de entrenamiento para la clasificación de modelos vehiculares. Tesis (Ingeniería Sistemas). Lima: Universidad de Lima 2022. Disponible en: https://repositorio.ulima.edu.pe/bitstream/handle/20.500.12724/18078/T018_71716684_T.pdf?sequence=1&isAllowed=y
- Business Empresarial, 2021. INEI: El 1.4% de peruanos del área urbana sufrió el robo de sus vehículos automotores entre noviembre y abril. En: Business Empresarial [en línea]. Disponible en: <https://www.businessempresarial.com.pe/inei-el-1-4-de-peruanos-del-area-urbana-sufrio-el-robo-de-sus-vehiculos-automotores-entre-noviembre-y-abril/>

-Caso 1- Población y muestra [Mensaje en blog]. RStudios: Zamora, L., (31 de octubre de 2022). [Fecha de consulta: 9 de octubre de 2022]. Recuperado de: <https://rpubs.com/LamecZamora/936775>

-Cómo funciona la metodología Scrum: Qué es y cómo utilizarla [Mensaje en Blog]. Sáez, Javier, (3 de diciembre de 2021). [Fecha de consulta: 27 de mayo de 2023]. Recuperado de: <https://www.iebschool.com/blog/metodologia-scrum-agile-scrum/>

-El Peruano, 2018: Disponen la publicación de proyecto de Decreto Supremo que modifica el Reglamento Nacional del Sistema de Emisión de Licencia de Conducir y su Exposición de Motivos, en el Portal Institucional del Ministerio. En: El Peruano [en línea]. Disponible en: <https://portal.mtc.gov.pe/transportes/terrestre/documentos/R.D.%20190-2018-MTC.pdf>

-Enfoque cuantitativo: métodos, fortalezas y debilidades. TestiForme. 01 de octubre de 2020. Disponible en: <https://www.testsiteforme.com/enfoque-cuantitativo/>

-FELTRAN, Gabriel y MALDONADO, Janaina. La economía de autos robados en São Paulo: mirada etnográfica sobre la reproducción de desigualdades y violencia en América Latina. *Etnográfica. Revista do Centro em Rede de Investigação em Antropologia*, 2022, vol. 26, no 1), p. 125-148. Disponible en: <https://journals.openedition.org/etnografica/11311>

-FERNANDEZ, Jhan. Sistema de reconocimiento de patrones con inteligencia artificial para detectar placas de vehículos requisitorizados para la Policía Nacional del Perú. Tesis (Ingeniería de Sistemas). Lima: Universidad César Vallejo, 2022. Disponible en: https://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/114869/Fernandez_AJC-SD.pdf?sequence=1&isAllowed=y

-FLORES, Vivar. Algorithms, applications and Big Data, new paradigms in the process of communication and teaching-learning of data journalism. *Revista de Comunicaciones* [en línea]. 17, 2, 10 de julio de 2018. [3 de mayo de 2023]. Disponible en: https://revistadecomunicacion.com/pdf/2018_2/12_Art.pdf
ISSN:1684-0933

FUJITSU, 2023. CCTV inteligente: el futuro de la vigilancia de la seguridad. En: FUJITSU [en línea]. Disponible en: <https://fujitsusouthamerica.com/es/cctv-inteligente-el-futuro-de-la-vigilancia-de-la-seguridad/>

-Giraldo, I. y Montoya, D. (2015). Aplicación de la metodología de Commonkads en la gestión del conocimiento. *Revista CEA*, 1(2), 99-108. [Fecha de consulta: 20 de mayo de 2029]. Disponible en: <https://doi.org/10.22430/24223182.133>

-Guía breve de técnicas de recolección de datos. SafetyCulture. 03 de abril de 2023. Disponible en: <https://acortar.link/n0l8Tl>

-HARNCHARNCHAI, A., SAEHEAW, T. (2017). Knowledge-based system with CommonKADS analysis for school botanical garden. *ACM International Conference Proceeding Series*, 402–407.

Disponible en: <https://doi.org/10.1145/3176653.3176658>

-Instituto Nacional de Estadística e Informática (INEI), 2021: Estadísticas de Seguridad Ciudadana. En: Instituto Nacional de Estadística e Informática (INEI) [en línea]. Disponible en: https://www.inei.gob.pe/media/MenuRecursivo/boletines/boletin_seguridad_nov_20_abr21.pdf

-Investigación aplicada. DuocUC. 20 de mayo de 2023. Disponible en: <https://bibliotecas.duoc.cl/investigacion-aplicada>

-Investigación Pre-Experimental. ONLINE-TESIS. 12 de diciembre de 2022. Disponible en: <https://online-tesis.com/investigacion-pre-experimental/>

-CHU, Victor. Sistema de Reconocimiento de Placas Vehiculares para Mejorar el Registro de Vehículos en el Hospedaje Suites Recreo - 2019. Tesis (Ingeniería de Sistemas). Lima: Universidad César Vallejo, 2019. Disponible en: https://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/41020/Chu_CVR.pdf?sequence=1&isAllowed=y

-Lessons learnt from COVID-19 surveillance. Urgent need for a new public health surveillance. SESPAS Report 2022 por Sierra Moros María [et al], [en línea]. Enero, 2022, 36, 68-75. [Fecha de consulta: 11 de mayo de 2023]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S0213911122000978>

-Martínez, 2020. ¿Qué es la Detección de Objetos? En: DataSmarts [en línea]. Disponible en: <https://datasmarts.net/es/que-es-la-deteccion-de-objetos/?fbclid=IwAR1an2Q1hCoAlsWodqjrttu2m0-VcLR7z55p8spPyn0KoxkxwIR-jVCecV4>

-Metodología Scrum: qué es y cómo aplicarla. Gitnux. 24 de febrero de 2023. Disponible en: <https://blog.gitnux.com/es/metodologia-scrum/>

-MONTERO, Susan y PONCE, Rafael. Sistema de monitoreo para la detección automática de placas de vehículos en Lima Metropolitana utilizando redes neuronales. Tesis (Ingeniería de Sistemas). Lima: Universidad Peruana de Ciencias Aplicadas, 2022. Disponible en: https://repositorioacademico.upc.edu.pe/bitstream/handle/10757/660720/Monte_ro_CS.pdf?sequence=3&isAllowed=y

-MOSAVI, Amir, RUIZ, Ramon y VARGAS Rocio. Deep Learning. [en línea]. 18 de octubre de 2018, 1. [Fecha de consulta: 11 de mayo de 2023]. Disponible en: <https://doi.org/10.20944/preprints201810.0218.v1>

-NIZAMA, David. Sistema de detección y clasificación vehicular basado en redes neuronales de aprendizaje profundo. Tesis (Ingeniero civil). Lima: Universidad Nacional de Ingeniería, 2022. Disponible en: <http://hdl.handle.net/20.500.14076/23816>

-PEREZ, Edwin. Reconocimiento de placas vehiculares mediante visión computacional para mejorar el acceso a un parqueadero. 2022. Tesis (Ingeniería de Sistemas). Pimentel: Universidad de Sipán. Disponible en: <https://repositorio.uss.edu.pe/bitstream/handle/20.500.12802/9897/Perez%20Silva%20Edwin%20Wildor.pdf?sequence=6&isAllowed=y>

-Población y muestra [Mensaje en blog]. Lifeder: Zapata, F., (9 de octubre de 2020). [Fecha de consulta: 9 de octubre de 2022]. Recuperado de <https://www.lifeder.com/poblacion-muestra/>

- ¿Qué es la inteligencia? eMS. 27 de enero de 2018. Disponible en: <https://www.elmundodelsuperdotado.com/que-es-la-inteligencia/>

- ¿Que es un sistema de videovigilancia y cómo funciona?. SeguriLatam. 30 de agosto de 2022. Disponible en: https://www.segurilatam.com/actualidad/que-es-un-sistema-de-videovigilancia-y-como-funciona_20220830.html#:~:text=Un%20sistema%20de%20videovigilancia%20sirve,v%C3%ADdeos%20recogidas%20por%20las%20c%C3%A1maras.

- ¿Qué es el reconocimiento de imágenes por IA y cómo funciona? Shaip. 17 de mayo de 2022. Disponible en: <https://es.shaip.com/blog/what-is-ai-image-recognition-and-how-does-it-work/>

- ¿Que es fiabilidad Test-Retest? (Definición y Ejemplo). Statologos. 2 de mayo de 2022. Disponible en: <https://statologos.com/prueba-reprueba-la-confiabilidad/>

-Scrum: qué es y cómo funciona este marco de trabajo [Mensaje en blog]. De Dios, Miguel, (9 de mayo de 2022). [Fecha de consulta: 27 de mayo de 2023]. Recuperado de: <https://www.wearemarketing.com/es/blog/metodologia-scrum-que-es-y-como-funciona.html>

-Smart data processing for energy harvesting systems using artificial intelligence por DIVYA, S. [et all], [en línea]. 01 de febrero de 2023, 16, 108084. [Fecha de consulta: 10 de mayo de 2023].

Disponible en: <https://doi.org/10.1016/j.nanoen.2022.108084>

ISSN:2211-2855

-TRACKLINK, 2022. ¿Qué tipo de placas de rodaje existen en Perú y cuáles son? En: TRACKLIK [en línea]. Disponible en:

<https://www.tracklink.pe/contenido/blog/cuales-son-los-tipos-de-placas-de-rodaje-en-peru/>

-WANG, Xizhao, ZHAO, Yanxia y POURPANAH, Farhad. Recent advances in deep learning. [en línea]. 20 de febrero de 2020, 11, 747-750. [Fecha de consulta: 10 de mayo de 2023].

Disponible en: <https://doi.org/10.1007/s13042-020-01096-5>

ANEXOS

Anexo 1: Matriz de operacionalización de variables

Tabla 22. Matriz de operacionalización de variable

Variable	Definición Conceptual	Definición Operacional	Dimensión	Indicador	Escala
Reconocimiento de vehículos y sus matrículas	La clasificación vehicular es la categorización que se realiza según ciertas características (Tarazona, 2018; Zoilo Ríos, S.A. 2021). La extracción de caracteres de una imagen se refiere al proceso de identificar y aislar caracteres o texto contenido en una imagen digital para su posterior procesamiento, análisis o conversión en texto legible por una computadora. (Ostrovskij, 2023).	El reconocimiento de vehículos se medirá a través de la detección de imágenes mediante la precisión, sensibilidad, F1 Score y precisión de reconocimiento de caracteres.	Extracción	Precisión de reconocimiento de caracteres $RA = \frac{RC}{TC} * 100$ RC = Reconocimiento de caracteres TC = Total de caracteres	Por intervalo: (0 – 100 en%)
			Clasificación	Precisión para clasificar los vehículos $p = \frac{TP}{TP + FP}$ FP = Falsos Positivos TP=Verdadero Positivo	
			F1 Score para clasificar los vehículos $f1 = 2 * \frac{(PRECISION * RECALL)}{PRECISION + RECALL}$ R =Recall P=Precisión		
			Sensibilidad para clasificar los vehículos $r = \frac{TP}{TP + FN}$ TP = Verdaderos Positivo FN = Falsos Negativos		

Anexo 2: Matriz de consistencia

Tabla 23: Matriz de consistencia

Problema General	Objetivo General	Hipótesis General	Variable Independiente	Dimensión	Indicadores	Fórmula	Método
¿Nuestro algoritmo inteligente podrá clasificar los vehículos y extraer los caracteres de las placas vehiculares?	Desarrollar un algoritmo inteligente para la clasificación de vehículos y para la extracción de los caracteres de las placas vehiculares.	El algoritmo inteligente clasificar los vehículos y extraer los caracteres de sus matriculas.	Algoritmo Inteligente				<p>Tipo de investigación: Aplicada</p> <p>Diseño de investigación: Pre-Experimental</p> <p>Población: 30 fotografías de vehículos.</p> <p>Muestra: 30 fotografías de vehículos</p> <p>Técnica: Observación</p> <p>Instrumento: Ficha de registro</p>
Problema Especifico	Objetivo Especifico	Hipótesis Especifico	Variable Dependiente	Dimensión	Indicadores	Fórmula	
<p>PE1 ¿Cómo el algoritmo inteligente clasificará los vehículos?</p> <p>PE2 ¿Cómo el algoritmo inteligente detectará las placas vehiculares?</p> <p>OE3 ¿Cómo el algoritmo inteligente extraerá los caracteres de las placas vehiculares?</p>	<p>OE1 Desarrollar un algoritmo inteligente que clasifique los vehículos,</p> <p>OE2 Desarrollar un algoritmo inteligente que detecte las placas</p> <p>OE3 Desarrollar un algoritmo inteligente que extraiga los</p>	<p>HE1 El algoritmo inteligente logra clasificar los vehículos</p> <p>HE2 El algoritmo inteligente logra detectar las placas</p> <p>HE3 El algoritmo inteligente logra extraer los caracteres</p>	Reconocimiento de vehículos y sus matriculas	Extracción	Precisión de reconocimiento de caracteres	$RA = \frac{RC}{TC} * 100$ <p>RC = Reconocimiento de caracteres TC = Total de caracteres</p>	
	Clasificación	Precisión para clasificar los vehículos		$p = \frac{TP}{TP + FP}$ <p>FP = Falsos Positivos TP=Verdadero Positivo</p>			
	F1 Score para clasificar los vehículos	$f1 = 2 * \frac{(PRECISION * RECALL)}{PRECISION + RECALL}$ <p>R =Recall P=Precisión</p>					
	Sensibilidad para clasificar los vehículos	$r = \frac{TP}{TP + FN}$ <p>TP = Verdaderos Positivo FN = Falsos Negativos</p>					

	caracteres de las placas.	de las placas vehiculares.					
--	---------------------------	----------------------------	--	--	--	--	--

Anexo 3: Instrumento de recolección de datos

Ficha de registro para la determinar la precisión en la clasificación de vehículos y extracción de placas	
Autor (es)	-Romero Pacheco Jhonatan Jhefersson -Outten Campos Eduardo Junior
Muestra Investigada	Fotografías de vehículos
Método de investigación	Pre-Experimental
Fecha de inicio	25/09/2023
Fecha de Fin	25/09/2023

Dimensión	Indicador	Medida	Fórmula
Clasificación	Precisión para clasificar los vehículos(P)	Intervalo	$p = \frac{TP}{TP + FP}$ FP = Falsos Positivos TP=Verdadero Positivo

Ítem	Fecha	Imagen	TP	FP	P
1	25/09/2023	IMG_1237_jpg	1	1	0,50
2	25/09/2023	IMG_1242_jpg	1	1	0,50
3	25/09/2023	IMG_1304_jpg	8	3	0,72
4	25/09/2023	IMG_1305_jpg	2	1	0,66
5	25/09/2023	IMG_1307_jpg	4	0	1,00
6	25/09/2023	IMG_1309_jpg	3	1	0,75
7	25/09/2023	IMG_1310_jpg	3	2	0,60
8	25/09/2023	IMG_1312_jpg	3	2	0,60
9	25/09/2023	IMG_1315_jpg	1	2	0,33
10	25/09/2023	IMG_1321_jpg	2	1	0,66
11	25/09/2023	IMG_1322_jpg	1	1	0,50
12	25/09/2023	IMG_1323_jpg	6	1	0,86
13	25/09/2023	IMG_1326_jpg	5	1	0,83
14	25/09/2023	IMG_1393_jpg	1	4	0,20
15	25/09/2023	IMG_1406_jpg	1	1	0,50
16	25/09/2023	IMG_1412_jpg	1	0	1,00
17	25/09/2023	IMG_1414_jpg	3	1	0,75
18	25/09/2023	IMG_1415_jpg	5	1	0,83
19	25/09/2023	IMG_1474_jpg	2	3	0,40
20	25/09/2023	IMG_1489_jpg	0	1	0,00
21	25/09/2023	IMG_1491_jpg	1	3	0,25
22	25/09/2023	IMG_1492_jpg	2	1	0,66
23	25/09/2023	IMG_1801_jpg	2	1	0,66
24	25/09/2023	IMG_1896_jpg	2	0	1,00
25	25/09/2023	IMG_2502_jpg	2	2	0,50
26	25/09/2023	IMG_2503_jpg	2	2	0,50
27	25/09/2023	IMG_2504_jpg	9	1	0,90
28	25/09/2023	IMG_2507_jpg	15	2	0,88
29	25/09/2023	IMG_2523_jpg	2	2	0,50
30	25/09/2023	IMG_2525_jpg	2	1	0,66
Promedio					0.62

Ficha de registro para la determinar la sensibilidad en la clasificación de vehículos y extracción de placas	
Autor (es)	-Romero Pacheco Jhonatan Jhefersson -Outten Campos Eduardo Junior
Muestra Investigada	Fotografías de vehículos
Método de investigación	Pre-Experimental
Fecha de inicio	25/09/2023
Fecha de Fin	25/09/2023

Dimensión	Indicador	Medida	Fórmula
Detección	Sensibilidad para detectar los vehículos(R)	Intervalo	$r = \frac{TP}{TP + FN}$ TP = Verdaderos Positivo FN = Falsos Negativos

Ítem	Fecha	Imagen	TP	FN	R
1	25/09/2023	IMG_1237_jpg	1	1	0,50
2	25/09/2023	IMG_1242_jpg	1	1	0,50
3	25/09/2023	IMG_1304_jpg	1	5	0,17
4	25/09/2023	IMG_1305_jpg	2	1	0,67
5	25/09/2023	IMG_1307_jpg	4	0	1,00
6	25/09/2023	IMG_1309_jpg	3	1	0,75
7	25/09/2023	IMG_1310_jpg	3	2	0,60
8	25/09/2023	IMG_1312_jpg	3	2	0,60
9	25/09/2023	IMG_1315_jpg	2	1	0,67
10	25/09/2023	IMG_1321_jpg	2	1	0,67
11	25/09/2023	IMG_1322_jpg	1	1	0,50
12	25/09/2023	IMG_1323_jpg	5	2	0,71
13	25/09/2023	IMG_1326_jpg	5	1	0,83
14	25/09/2023	IMG_1393_jpg	3	2	0,60
15	25/09/2023	IMG_1406_jpg	1	1	0,50
16	25/09/2023	IMG_1412_jpg	1	0	1,00
17	25/09/2023	IMG_1414_jpg	3	1	0,75
18	25/09/2023	IMG_1415_jpg	5	2	0,71
19	25/09/2023	IMG_1474_jpg	2	3	0,40
20	25/09/2023	IMG_1489_jpg	1	0	1,00
21	25/09/2023	IMG_1491_jpg	1	3	0,25
22	25/09/2023	IMG_1492_jpg	2	1	0,66
23	25/09/2023	IMG_1801_jpg	2	1	0,66
24	25/09/2023	IMG_1896_jpg	2	0	1,00
25	25/09/2023	IMG_2502_jpg	1	3	0,25
26	25/09/2023	IMG_2503_jpg	2	2	0,50
27	25/09/2023	IMG_2504_jpg	9	1	0,90
28	25/09/2023	IMG_2507_jpg	15	2	0,88
29	25/09/2023	IMG_2523_jpg	2	2	0,50
30	25/09/2023	IMG_2525_jpg	2	1	0,67
Promedio					0,64

Ficha de registro para la determinar la F1-score en la clasificación de vehículos y extracción de placas	
Autor (es)	-Romero Pacheco Jhonatan Jhefersson -Outten Campos Eduardo Junior
Muestra Investigada	Fotografías de vehículos
Método de investigación	Pre-Experimental
Fecha de inicio	25/09/2023
Fecha de Fin	25/09/2023

Dimensión	Indicador	Medida	Fórmula
Clasificación	F1 Score para clasificar los vehículos(F1)	Intervalo	$f1 = 2 * \frac{(PRECISION * RECALL)}{PRECISION + RECALL}$ R =Recall P=Precisión

Ítem	Fecha	Imagen	R	P	F1
1	25/09/2023	IMG_1237_jpg	0,50	0,50	0,50
2	25/09/2023	IMG_1242_jpg	0,50	0,50	0,50
3	25/09/2023	IMG_1304_jpg	0,17	0,72	0,26
4	25/09/2023	IMG_1305_jpg	0,67	0,66	0,66
5	25/09/2023	IMG_1307_jpg	1,00	1,00	1,00
6	25/09/2023	IMG_1309_jpg	0,75	0,75	0,75
7	25/09/2023	IMG_1310_jpg	0,60	0,60	0,60
8	25/09/2023	IMG_1312_jpg	0,60	0,60	0,60
9	25/09/2023	IMG_1315_jpg	0,67	0,33	0,42
10	25/09/2023	IMG_1321_jpg	0,67	0,66	0,63
11	25/09/2023	IMG_1322_jpg	0,50	0,50	0,50
12	25/09/2023	IMG_1323_jpg	0,71	0,86	0,77
13	25/09/2023	IMG_1326_jpg	0,83	0,83	0,83
14	25/09/2023	IMG_1393_jpg	0,60	0,20	0,30
15	25/09/2023	IMG_1406_jpg	0,50	0,50	0,50
16	25/09/2023	IMG_1412_jpg	1,00	1,00	1,00
17	25/09/2023	IMG_1414_jpg	0,75	0,75	0,75
18	25/09/2023	IMG_1415_jpg	0,71	0,83	0,76
19	25/09/2023	IMG_1474_jpg	0,40	0,40	0,40
20	25/09/2023	IMG_1489_jpg	1,00	0,00	0,00
21	25/09/2023	IMG_1491_jpg	0,25	0,25	0,25
22	25/09/2023	IMG_1492_jpg	0,66	0,66	0,66
23	25/09/2023	IMG_1801_jpg	0,66	0,66	0,66
24	25/09/2023	IMG_1896_jpg	1,00	1,00	1,00
25	25/09/2023	IMG_2502_jpg	0,25	0,50	0,33
26	25/09/2023	IMG_2503_jpg	0,50	0,50	0,50
27	25/09/2023	IMG_2504_jpg	0,90	0,90	0,90
28	25/09/2023	IMG_2507_jpg	0,88	0,88	0,88
29	25/09/2023	IMG_2523_jpg	0,50	0,50	0,50
30	25/09/2023	IMG_2525_jpg	0,67	0,66	0,66
Promedio					0,60

Ficha de registro para la determinar la precisión de reconocimiento de caracteres en la clasificación de vehículos y extracción de placas	
Autor (es)	-Romero Pacheco Jhonatan Jhefersson -Outten Campos Eduardo Junior
Muestra Investigada	Fotografías de vehículos
Método de investigación	Pre-Experimental
Fecha de inicio	25/09/2023
Fecha de Fin	25/09/2023

Dimensión	Indicador	Medida	Fórmula
Extracción	Precisión de reconocimiento de caracteres (CRA)	Intervalo	$CRA = \frac{RC}{TC} * 100$ RC = Reconocimiento de caracteres TC =Total de caracteres

Ítem	Fecha	Imagen	RC	TC	CRA
1	25/09/2023	IMG_1237_jpg	3	6	0,50
2	25/09/2023	IMG_1237_jpg	5	6	0,83
3	25/09/2023	IMG_1242_jpg	5	6	0,83
4	25/09/2023	IMG_1302_jpg	6	6	1,00
5	25/09/2023	IMG_1307_jpg	4	6	0,66
6	25/09/2023	IMG_1309_jpg	4	6	0,66
7	25/09/2023	IMG_1310_jpg	3	6	0,50
8	25/09/2023	IMG_1323_jpg	4	6	0,66
9	25/09/2023	IMG_1326_jpg	2	6	0,33
10	25/09/2023	IMG_1393_jpg	3	6	0,50
11	25/09/2023	IMG_1414_jpg	4	6	0,66
12	25/09/2023	IMG_1896_jpg	4	6	0,66
13	25/09/2023	IMG_2502_jpg	3	6	0,50
14	25/09/2023	IMG_2502_jpg	3	6	0,50
15	25/09/2023	IMG_2502_jpg	5	6	0,83
16	25/09/2023	IMG_2502_jpg	4	6	0,66
17	25/09/2023	IMG_2502_jpg	3	6	0,50
18	25/09/2023	IMG_2503_jpg	3	6	0,50
19	25/09/2023	IMG_2503_jpg	4	6	0,66
20	25/09/2023	IMG_2503_jpg	5	6	0,83
21	25/09/2023	IMG_2504_jpg	2	6	0,33
22	25/09/2023	IMG_2504_jpg	6	6	1,00
23	25/09/2023	IMG_2507_jpg	5	6	0,83
24	25/09/2023	IMG_2507_jpg	3	6	0,50
25	25/09/2023	IMG_2523_jpg	4	6	0,66
26	25/09/2023	IMG_2523_jpg	3	6	0,50
27	25/09/2023	IMG_2523_jpg	2	6	0,33
28	25/09/2023	IMG_2525_jpg	4	6	0,66
29	25/09/2023	IMG_2525_jpg	2	6	0,33
30	25/09/2023	IMG_2525_jpg	3	6	0,50
Promedio					0,61

Anexo 4: Carta de autorización de publicación de tesis

	<p>AUTORIZACIÓN DE PUBLICACIÓN DE TESIS EN REPOSITORIO INSTITUCIONAL UCV</p>	<p>Código: F08-PP-PR-02.02 Versión: Fecha: 15-11-2023 Página: 1 de 1</p>
--	---	---

Nosotros, Jhonatan Jhefersson Romero Pacheco identificado con DNI N.º 70101486 y Eduardo Junior Outten Campos identificado con DNI N.º 73252849 egresados de la Escuela Profesional de Ingeniería de Sistemas de la Universidad César Vallejo Lima Norte, autorizo (X) , No autorizo () la divulgación y comunicación pública de mi trabajo de investigación titulado “Algoritmo inteligente para la clasificación de vehículos y la extracción de caracteres de las placas vehiculares”; en el Repositorio Institucional de la UCV (<http://repositorio.ucv.edu.pe/>), según lo estipulado en el Decreto Legislativo 822, Ley sobre Derecho de Autor, Art. 23 y Art. 33

Fundamentación en caso de no autorización:

.....

.....

.....

.....

.....

.....

.....

.....

.....

.....

FIRMA
 NOMBRE: Jhonatan Jhefersson Romero Pacheco
 DNI: 70101486
 FECHA: 15 de noviembre del 2023

FIRMA
 NOMBRE: Eduardo Junior Outten Campos
 DNI: 73252849
 FECHA: 15 de noviembre del 2023


Elaboró	Dirección de investigación	Revisó	Representante de la dirección / Vicerrectorado de investigación y Calidad	Aprobó	Rectorado
---------	----------------------------	--------	---	--------	-----------

Anexo 6: Desarrollo y Prototipo


Roboflow



Goggle Colab (Mesa de trabajo final)



Goggle Colab (Entrenamiento)



Arquitectura CNN (Darknet)

Esta arquitectura es brindada por la herramienta de Yolo

```
detection.py M | h darknet X | CcrText.py M | views.py M
darknet > include > h darknet
1831
1832 // network.h
1833 LIB_API float *network_predict(network net, float *input);
1834 LIB_API float *network_predict_ptr(network *net, float *input);
1835 #ifdef CUDA_OPEMGL_INTEGRATION
1836 LIB_API float *network_predict_gl_texture(network *net, uint32_t texture_id);
1837 #endif // CUDA_OPEMGL_INTEGRATION
1838
1839 LIB_API void set_batch_network(network *net, int b);
1840 LIB_API detection *get_network_boxes(network *net, int w, int h, float thresh, float hier, int *map, int relative, int *num, int letter);
1841 LIB_API det_num_pair* network_predict_batch(network *net, image im, int batch_size, int w, int h, float thresh, float hier, int *map, int relative, int letter);
1842 LIB_API void free_detections(detection *dets, int n);
1843 LIB_API void free_batch_detections(det_num_pair *det_num_pairs, int n);
1844 LIB_API void fuse_conv_batchnorm(network net);
1845 LIB_API void calculate_binary_weights(network net);
1846 LIB_API char *detection_to_json(detection *dets, int nboxes, int classes, char **names, long long int frame_id, char *filename);
1847
1848 LIB_API layer* get_network_layer(network* net, int i);
1849 //LIB_API detection *get_network_boxes(network *net, int w, int h, float thresh, float hier, int *map, int relative, int *num, int letter);
1850 LIB_API detection *make_network_boxes(network *net, float thresh, int *num);
1851 LIB_API void reset_rnn(network *net);
1852 LIB_API float *network_predict_image(network *net, image im);
1853 LIB_API float *network_predict_image_letterbox(network *net, image im);
1854 LIB_API float validate_detector_map(char *datacfg, char *cfgfile, char *weightfile, float thresh_calc_avg_iou, const float iou_thresh, const int map_points, int letter_box, net
1855 LIB_API void train_detector(char *datacfg, char *cfgfile, char *weightfile, int *gpus, int ngpus, int clear, int dont_show, int calc_map, float thresh, float iou_thresh, int n)
1856 LIB_API void test_detector(char *datacfg, char *cfgfile, char *weightfile, char *filename, float thresh,
1857 float hier_thresh, int dont_show, int ext_output, int save_labels, char *outfile, int letter_box, int benchmark_layers);
1858 LIB_API int network_width(network *net);
1859 LIB_API int network_height(network *net);
1860 LIB_API void optimize_picture(network *net, image orig, int max_layer, float scale, float rate, float thresh, int norm);
1861
1862 // image.h
1863 LIB_API void make_image_red(image im);
1864 LIB_API image make_attention_image(int img_size, float *original_delta_cpu, float *original_input_cpu, int w, int h, int c, float alpha);
1865 LIB_API image resize_image(image im, int w, int h);
1866 LIB_API void quantize_image(image im);
1867 LIB_API void copy_image_from_bytes(image im, char *pdata);
1868 LIB_API image letterbox_image(image im, int w, int h);
1869 LIB_API void copy_image(image im);
```

Así mismo la arquitectura la reutilizamos para los entrenamientos

```
# train
dataset1_train = "/content/darknet/dataset/train/"
count_train={
    'Bus':0,
    'Bus_de_carga':0,
    'Carro':0
}
count_train_final_dataset1 = change_class(dataset1_train,cambios_bus,cambios_bus_carga,cambios_carro,count_train)
print("Entrenamiento",count_train_final_dataset1)

dataset1_valid = "/content/darknet/dataset/valid/"
count_train={
    'Bus':0,
    'Bus_de_carga':0,
    'Carro':0
}
count_valid_final_dataset1 = change_class(dataset1_valid,cambios_bus,cambios_bus_carga,cambios_carro,count_train)
print("Valid",count_valid_final_dataset1)
# test
dataset1_test = "/content/darknet/dataset/test/"
count_test={
    'Bus':0,
    'Bus_de_carga':0,
    'Carro':0
}
count_test_final_dataset1 = change_class(dataset1_test,cambios_bus,cambios_bus_carga,cambios_carro,count_test)
print("Test",count_test_final_dataset1)

Entrenamiento {'Bus': 198, 'Bus_de_carga': 192, 'Carro': 914}
Valid {'Bus': 46, 'Bus_de_carga': 60, 'Carro': 238}
Test {'Bus': 38, 'Bus_de_carga': 20, 'Carro': 150}
```

Local

```
File Edit Selection View Go Run ...
detection.py M x OcrText.py M views.py M
detection.py
13 import json
14
15 def convert2relative(image, bbox):
16     """
17     YOLO format use relative coordinates for annotation
18     """
19     x, y, w, h = bbox
20     height, width, _ = image.shape
21     return x/width, y/height, w/width, h/height
22
23 def save_image_to_directory(name,directorio_predictions,image):
24     if not os.path.exists(directorio_predictions):
25         os.makedirs(directorio_predictions)
26         print("directorio creado",directorio_predictions)
27         nombre_base, extension = os.path.splitext(os.path.basename(name)) #
28         name_txt = nombre_base+"_anotaciones"+".txt"
29         # save image
30         filename = str(time.time()+extension)
31         name_image = os.path.join(directorio_predictions, filename) # Ruta completa del archivo+
32         cv2.imwrite(name_image,image)
33         return filename,name_txt
34
35 def max_save_annotatons(directorio_created,file_annotacion,redis_client):
36     with open(file_annotacion, "r") as file:
37         lines = file.readlines()
38         # Inicializa variables para el máximo valor y su índice
39         max_value_1 = float("-inf")
40         max_value_2 = float("-inf")
41         max_value_3 = float("-inf")
42         max_value_4 = float("-inf")
43         # Encuentra el índice con el máximo valor en la última columna
44         for index, line in enumerate(lines):
45             parts = line.split()
```

Clasificación y Extracción en el sistema

The screenshot shows a web application interface for vehicle detection. The interface includes a sidebar with navigation links (Inicio, Detección, Reportes), a main area with "Subir Imagen" and "Detectar imagen" buttons, a preview image of a red car, and a table listing detected vehicles with their repository IDs, descriptions, and actions.

#	Nombre Archivo Detectado	Repositorio	Descripción	Acciones
1	IMG_1237.jpg	1698810632.4244509	2 carros,0 bus de carga , 0 taxi , 0 buses	Eliminar Descargar imagen detectada Descargar anotaciones
2	IMG_1237.jpg	1698811322.788528	2 carros,0 bus de carga , 0 taxi , 0 buses	Eliminar Descargar imagen detectada Descargar anotaciones
3	IMG_1406.jpg	1699063763.1150205	1 carros,0 bus de carga , 0 taxi , 0 buses	Eliminar Descargar imagen detectada Descargar anotaciones
4	IMG_1310.jpg	1699064574.0614274	3 carros,0 bus de carga , 0 taxi , 3 buses	Eliminar Descargar imagen detectada Descargar anotaciones
5	IMG_1412.jpg	1699135411.8999455	1 carros,1 bus de carga , 0 taxi , 0 buses	Eliminar Descargar imagen detectada Descargar anotaciones
6	IMG_1251.jpg	1699139915.7565968	2 carros,0 bus de carga , 0 taxi , 0 buses	Eliminar Descargar imagen detectada Descargar anotaciones

Clasificación de vehículos



Extracción de placas vehiculares

	F2F-0295
	88y953
	Brp9Ajel
	BREE



UNIVERSIDAD CÉSAR VALLEJO

**FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS**

Declaratoria de Autenticidad del Asesor

Yo, NECOCHEA CHAMORRO JORGE ISAAC, docente de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA DE SISTEMAS de la UNIVERSIDAD CÉSAR VALLEJO SAC - LIMA NORTE, asesor de Tesis titulada: "Algoritmo inteligente para la clasificación de vehículos y extracción de caracteres de las placas vehiculares", cuyos autores son OUTTEN CAMPOS EDUARDO JUNIOR, ROMERO PACHECO JHONATAN JHEFERSSON, constato que la investigación tiene un índice de similitud de 18.00%, verificable en el reporte de originalidad del programa Turnitin, el cual ha sido realizado sin filtros, ni exclusiones.

He revisado dicho reporte y concluyo que cada una de las coincidencias detectadas no constituyen plagio. A mi leal saber y entender la Tesis cumple con todas las normas para el uso de citas y referencias establecidas por la Universidad César Vallejo.

En tal sentido, asumo la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión tanto de los documentos como de información aportada, por lo cual me someto a lo dispuesto en las normas académicas vigentes de la Universidad César Vallejo.

LIMA, 28 de Noviembre del 2023

Apellidos y Nombres del Asesor:	Firma
NECOCHEA CHAMORRO JORGE ISAAC DNI: 18167347 ORCID: 0000-0002-3290-8975	Firmado electrónicamente por: JNECOCHEA el 28- 11-2023 09:21:11

Código documento Trilce: TRI - 0669087