

Impacto del desarrollo de un prototipo de software con reconocimiento de placas en la eficiencia del control de acceso vehicular en la mina de la comunidad de Pochuanca – Aymaraes, 2024

Impact of the Development of a License Plate Recognition Software Prototype on the Efficiency of Vehicular Access Control at the Pochuanca Community Mine, Aymaraes, 2024



Rosmery Sánchez-Espinoza

Universidad Nacional Micaela Bastidas de Apurímac
<https://orcid.org/0009-0005-0540-5124>
171175@unamba.edu.pe

Erech Ordoñez-Ramos

Universidad Nacional Micaela Bastidas de Apurímac
<https://orcid.org/0000-0002-3058-9683>
eordonhez@unamba.edu.pe

Alejandrina Huaylla-Quispe

Universidad Nacional Micaela Bastidas de Apurímac
<https://orcid.org/0000-0002-0258-8632>
ahuaylla@unamba.edu.pe

Universidad Nacional Micaela Bastidas de Apurímac – Perú
 Riqchary, revista de investigación en ciencia y tecnología
[ISSN: 2810-8124 \(en línea\) / ISSN: 2706-543x](https://doi.org/10.57166/riqchary/v8.n1.2026)
 Vol. 8 Núm. 1 (2026) - Publicado: 01/04/2026
doi.org/10.57166/riqchary/v8.n1.2026
 Páginas: 1 - 10
 Recibido 01/01/2025 ; Aceptado 01/02/2025
<https://doi.org/10.57166/riqchary/v8.n1.2026.4>

Resumen— El presente estudio evalúa el impacto del desarrollo de un prototipo de software con reconocimiento automático de placas vehiculares en la eficiencia del control de acceso en la mina de la comunidad de Pochuanca, Aymaraes. El sistema fue diseñado para operar en condiciones reales no controladas, utilizando una cámara fija, un modelo de detección basado en YOLOv8n y una plataforma de procesamiento embebido sobre Raspberry Pi 5. Durante la etapa de entrenamiento, el modelo alcanzó altos valores de precisión, recall y mAP@0.5, evidenciando un aprendizaje estable bajo condiciones controladas. Posteriormente, el sistema fue evaluado en operación real mediante transmisión de video en tiempo real, enfrentando variaciones de iluminación, presencia de polvo y distintas velocidades de tránsito vehicular. Los resultados mostraron que, si bien la detección de placas se mantuvo estable, el reconocimiento óptico de caracteres presentó limitaciones, lo que motivó la incorporación de un mecanismo de validación humana asistida. Asimismo, se implementó un proceso de depuración temporal para evitar la sobreestimación de eventos. En conjunto, el prototipo demostró ser viable para el registro continuo de eventos vehiculares, facilitando la gestión, depuración y análisis de la información de acceso en un entorno operativo real.

Palabras clave: Control vehicular; reconocimiento de placas; visión por computador.

Abstract— This study evaluates the impact of developing a software prototype with automatic vehicle license plate recognition on the efficiency of access control at the mine of the Pochuanca community, Aymaraes. The system was designed to operate under real, uncontrolled conditions, using a fixed camera, a YOLOv8n-based detection model, and an embedded processing platform running on a Raspberry Pi 5. During the training stage, the model achieved high precision, recall, and mAP@0.5 values, demonstrating stable learning under controlled conditions. Subsequently, the system was evaluated in real operation through real-time video streaming, facing challenges such as lighting variations, dust presence, and different vehicle speeds. The results showed that while license plate detection remained stable, optical character recognition exhibited limitations, leading to the incorporation of a human-assisted validation mechanism. In addition, a temporal filtering process was implemented to avoid event overestimation. Overall, the prototype proved to be a viable solution for continuous vehicle event registration, facilitating access management, temporal filtering, and subsequent analysis of access information in a real operational environment.

Keywords: Computer vision; license plate recognition; vehicle access control.

1 INTRODUCCIÓN

El control de acceso vehicular constituye un proceso crítico para garantizar la seguridad, trazabilidad y orden operativo en entornos industriales y productivos. Diversos estudios han demostrado que los sistemas automatizados de autenticación vehicular permiten fortalecer los mecanismos de seguridad y reducir vulnerabilidades asociadas a registros manuales [1], [2], [3]. En contextos donde existe un flujo constante de vehículos, como instalaciones mineras, la correcta identificación de las unidades que ingresan y salen resulta fundamental para la gestión operativa y la prevención de accesos no autorizados. No obstante, en escenarios de minería comunitaria o artesanal, estos procesos suelen ejecutarse mediante registros manuales, lo que incrementa la probabilidad de errores humanos, genera demoras en el registro y limita la disponibilidad de información confiable para el análisis histórico y la toma de decisiones, situación ampliamente reportada en estudios sobre sistemas de vigilancia vehicular en entornos reales [4].

Diversos estudios han señalado que los sistemas tradicionales de control manual presentan deficiencias significativas en términos de eficiencia y precisión, especialmente cuando el volumen de registros aumenta o las condiciones de operación no permiten una verificación exhaustiva en tiempo real. En respuesta a estas limitaciones, los sistemas de control de acceso vehicular basados en tecnologías de visión artificial y reconocimiento automático de placas vehiculares (ALPR, por sus siglas en inglés) han emergido como una alternativa eficaz no solo para la autenticación vehicular, sino también para la automatización del registro, la trazabilidad de eventos y la generación de información histórica para la toma de decisiones [1], [2], [3], [5].

El reconocimiento automático de placas vehiculares se fundamenta en un flujo de procesamiento que comprende la detección de la placa dentro de la imagen, la delimitación o recorte de la región de interés y la posterior conversión de los caracteres a texto mediante reconocimiento óptico de caracteres (OCR). La literatura especializada ha demostrado que la incorporación de modelos de aprendizaje profundo, particularmente aquellos orientados a la detección de objetos en tiempo real, ha permitido alcanzar altos niveles de precisión y robustez frente a variaciones de escala, iluminación y perspectiva [6], [7], [8]. En particular, las arquitecturas de la familia YOLO han sido ampliamente adoptadas debido a su equilibrio entre exactitud y velocidad de inferencia, destacándose como detectores de una sola etapa con capacidad de procesamiento eficiente en escenarios dinámicos [6], [7], [8]. Asimismo, investigaciones recientes evidencian que este tipo de arquitecturas puede desplegarse eficazmente en entornos de edge computing, donde el procesamiento local de flujos de video reduce la latencia y mejora la autonomía del sistema en infraestructuras con recursos limitados [9]. En aplicaciones de vigilancia vehicular basadas en video continuo, estos enfoques han demostrado ser adecuados para el monitoreo y conteo automatizado de vehículos en condiciones

reales de operación [4], [10].

Sin embargo, múltiples investigaciones coinciden en que, aun cuando la detección y localización de placas vehiculares presentan un desempeño satisfactorio, la etapa de reconocimiento de caracteres continúa siendo un desafío en condiciones reales de operación. Factores como suciedad en las placas, desgaste físico, desenfoque por movimiento, variaciones tipográficas y condiciones ambientales adversas afectan negativamente la fiabilidad del OCR, generando errores en la transcripción automática de los caracteres [5], [11]. Estas limitaciones han motivado el uso de enfoques híbridos que incorporan validación humana asistida, con el fin de garantizar la integridad del dato final utilizado en los sistemas de información [5], [11].

De manera paralela, el avance de los dispositivos embebidos ha permitido implementar soluciones de visión artificial con costos reducidos y despliegue local. Plataformas como Raspberry Pi han demostrado ser viables para ejecutar modelos de detección basados en aprendizaje profundo en escenarios reales, facilitando la instalación de sistemas autónomos de control de acceso sin requerir infraestructura de cómputo centralizada. Este enfoque resulta especialmente pertinente en entornos mineros comunitarios, donde las restricciones de conectividad y recursos tecnológicos demandan soluciones eficientes y de bajo costo, alineadas con el paradigma de inteligencia en el borde (*edge intelligence*) [9].

En este marco, el presente artículo evalúa el impacto del desarrollo de un prototipo de software con reconocimiento de placas en la eficiencia del control de acceso vehicular en la mina de la comunidad de Pochuanca – Aymaraes. El sistema desarrollado emplea un modelo de detección de placas entrenado específicamente para el contexto nacional, capaz de identificar y recortar automáticamente las placas vehiculares como evidencia visual del evento, en concordancia con enfoques basados en redes neuronales profundas para detección vehicular en tiempo real [6], [7], [12]. No obstante, debido a las limitaciones observadas en el reconocimiento automático de caracteres bajo condiciones reales de operación – como variaciones de iluminación, distorsión y ruido visual – ampliamente documentadas en la literatura sobre ALPR [11], [5] el prototipo incorpora un mecanismo de corrección manual del texto reconocido, almacenando el valor final validado en el campo *placa_corregida*, el cual es utilizado como referencia para los análisis estadísticos y la generación de reportes. Este enfoque híbrido permite combinar la automatización del proceso de captura con la confiabilidad del dato final, estrategia coherente con propuestas recientes sobre despliegue de sistemas de visión en entornos no controlados [4], asegurando así una evaluación objetiva del impacto del sistema en términos de eficiencia y precisión del control de acceso vehicular.

El impacto evaluado en esta investigación se centra en la mejora de la eficiencia operativa del control de acceso vehicular, entendida como la capacidad del sistema para

automatizar el registro de eventos, reducir ambigüedades en la identificación vehicular y consolidar detecciones redundantes mediante mecanismos de agrupación temporal. Diversos estudios han señalado que los sistemas basados en reconocimiento automático de placas contribuyen significativamente a la optimización del control de accesos y la trazabilidad de eventos en entornos industriales [1], [2], [3]. Asimismo, la integración de modelos de detección en tiempo real y plataformas de procesamiento en el borde (edge computing) favorece la reducción de latencia y la disponibilidad inmediata de información estructurada para su análisis posterior [4], [9]. En este sentido, el impacto se analiza en comparación con el método tradicional manual empleado en la unidad minera de Pochuanca, considerando mejoras en precisión del registro, reducción de ambigüedades y disponibilidad de datos históricos confiables.

2 MATERIALES Y MÉTODOS

2.1 Sistema tradicional de control vehicular

En la unidad minera de Pochuanca, el control de ingreso y salida de vehículos se realiza actualmente mediante un registro manual consignado en un único cuaderno físico, administrado por un controlador de acceso cuya asignación es de carácter temporal. En este procedimiento, el operador registra de forma manuscrita el nombre del conductor, la placa del vehículo y los horarios de subida y bajada, constituyéndose este mecanismo como una práctica habitual sin el soporte de un sistema automatizado formal.

Este método depende exclusivamente de la observación y transcripción manual de la información, lo que genera variabilidad en los formatos de registro, presencia de tachaduras y problemas de legibilidad. Asimismo, la consulta de información histórica y la obtención de estadísticas sobre el flujo vehicular requieren una revisión manual del cuaderno, incrementando el tiempo de análisis y la probabilidad de errores humanos. Estas condiciones establecen la línea base operativa frente a la cual se evalúa el sistema prototipo de reconocimiento de placas vehiculares desarrollado en esta investigación, el cual no reemplaza al procedimiento existente, sino que permite analizar su desempeño y potencial impacto en el control de acceso vehicular.

2.2 Entorno de implementación del sistema automatizado

El sistema automatizado de reconocimiento de placas vehiculares se implementó y ejecutó sobre una plataforma embebida basada en una Raspberry Pi 5 con 4 GB de memoria RAM, utilizando como sistema operativo Raspberry Pi OS. El desarrollo del software se realizó en Python versión 3.10.11, integrando librerías especializadas para visión por computador, aprendizaje profundo y gestión de datos.

Para la adquisición de imágenes, se empleó una cámara USB ELP 4K de enfoque varifocal y zoom manual,

instalada en un punto fijo sobre una ventana de una vivienda ubicada en la única vía de ingreso y salida vehicular hacia la unidad minera de Pochuanca. Esta instalación se realizó de manera provisional, permitiendo la captura continua del tránsito vehicular en condiciones reales de operación.

El procesamiento visual se basó en un modelo YOLOv8n, seleccionado debido a sus bajos requerimientos computacionales y su adecuada capacidad de detección en dispositivos con recursos limitados. Dicho modelo fue utilizado para la detección automática de placas vehiculares en tiempo real, a partir de las cuales se generaron recortes de las regiones de interés correspondientes a cada evento.

Sobre las imágenes recortadas, se aplicó un proceso de reconocimiento óptico de caracteres (OCR) mediante EasyOCR y Tesseract. Sin embargo, debido a la variabilidad de iluminación, ángulos de captura y condiciones ambientales propias del entorno, el OCR no presentó resultados confiables de forma consistente. En consecuencia, el sistema incorporó un enfoque de validación humana asistida, permitiendo que el operador corrigiera manualmente el texto de la placa detectada a través de un campo denominado *placa corregida*, el cual fue utilizado como referencia para el análisis estadístico posterior.

Todos los eventos detectados se almacenaron en una base de datos SQLite, registrando información como la placa reconocida por OCR, la placa corregida manualmente, la fecha y hora del evento, la imagen recortada, los niveles de confianza del detector y del OCR, así como el origen del evento. Adicionalmente, se desarrolló una interfaz web de administración que permitió la visualización y edición de registros, el filtrado por fechas y placas, la detección de eventos duplicados en ventanas temporales y la exportación de resultados en formatos Excel, CSV y PDF.

2.3 Modelo de detección de placas vehiculares

Para la detección automática de placas vehiculares se empleó el modelo YOLOv8n, perteneciente a la familia *You Only Look Once* (YOLO), el cual fue seleccionado debido a sus bajos requerimientos computacionales y su adecuada capacidad de detección en tiempo real. Esta elección se fundamenta en la eficiencia demostrada por los detectores de una sola etapa de la familia YOLO, ampliamente reconocidos por su equilibrio entre precisión y velocidad de inferencia en aplicaciones de visión por computador en tiempo real [8], [7]. Asimismo, trabajos orientados a la detección y reconocimiento vehicular mediante redes neuronales profundas respaldan la idoneidad de este tipo de arquitecturas para escenarios dinámicos y sistemas embebidos [12]. Esta selección respondió directamente a las restricciones de hardware impuestas por la plataforma de ejecución, basada en una Raspberry Pi 5, cuyos recursos son limitados en comparación con estaciones de trabajo convencionales.

El modelo YOLOv8n se utilizó exclusivamente para la

tarea de detección y localización de placas vehiculares, delimitando la región de interés mediante cajas delimitadoras (*bounding boxes*). A partir de estas detecciones, el sistema generó automáticamente recortes de las placas, los cuales fueron almacenados como evidencia visual del evento y utilizados en las etapas posteriores del procesamiento.

La configuración del detector se orientó a priorizar la robustez de detección en condiciones reales, considerando variaciones de escala, ángulo de captura y condiciones de iluminación propias del entorno de operación. El uso de un modelo liviano permitió mantener un equilibrio adecuado entre precisión y velocidad de inferencia, garantizando un desempeño estable durante la ejecución continua del sistema en tiempo real.

Es importante señalar que el alcance del modelo se limitó deliberadamente a la detección de placas, sin integrar la identificación directa de caracteres dentro de la red neuronal. Esta decisión metodológica permitió separar claramente la etapa de localización visual (que presentó un alto nivel de confiabilidad) de la etapa de reconocimiento de texto, la cual fue tratada de manera independiente debido a las limitaciones observadas en el entorno de aplicación.

2.4 Flujo de procesamiento y gestión de eventos vehiculares

El sistema automatizado de reconocimiento de placas vehiculares fue diseñado bajo un flujo secuencial de procesamiento que permitió gestionar de manera estructurada la captura, validación y almacenamiento de los eventos vehiculares detectados en condiciones reales de operación. El flujo general del sistema se resume en la Figura 1, donde se describen las principales etapas de procesamiento implementadas en la plataforma embebida. Cabe destacar que la validación humana asistida mantiene una relación bidireccional con la base de datos, ya que los registros automáticos son consultados, corregidos y actualizados posteriormente por el operador, consolidando así la información final utilizada para el análisis estadístico.

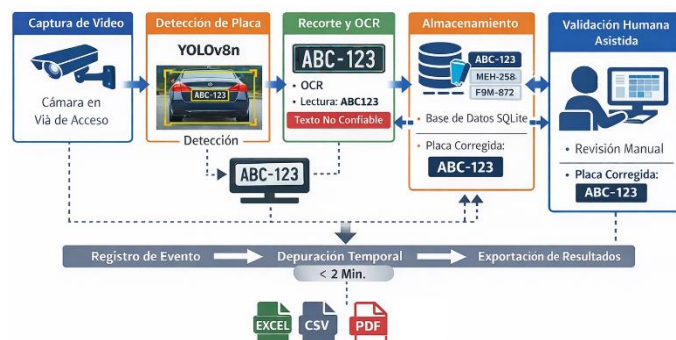


Fig. 1. Flujo de procesamiento del sistema automatizado.

Tal como se ilustra en la Figura 1, el sistema adquirió de forma continua imágenes desde la cámara fija instalada en la vía de acceso, transmitiendo el flujo de video en tiempo

real hacia la Raspberry Pi 5. No obstante, con el fin de optimizar el uso de recursos computacionales y evitar detecciones redundantes, el proceso de detección de placas vehiculares se ejecutó de manera periódica, aplicando un intervalo temporal de 3 segundos entre ciclos consecutivos de detección.

En cada ciclo, los cuadros seleccionados fueron procesados por el modelo YOLOv8n, encargado de identificar automáticamente la presencia de placas vehiculares y generar las correspondientes cajas delimitadoras. A partir de estas detecciones, el sistema extrajo de manera automática la región de interés correspondiente a la placa, generando recortes de imagen que fueron almacenados como evidencia visual de cada evento detectado.

Sobre las imágenes recortadas se aplicó un proceso de reconocimiento óptico de caracteres (OCR); sin embargo, debido a las condiciones reales de captura –variaciones de iluminación, ángulo de visión y presencia de polvo–, los resultados obtenidos no fueron confiables de forma consistente. Por este motivo, el sistema incorporó un mecanismo de validación humana asistida, mediante el cual el operador corrigió manualmente el texto de la placa detectada, almacenando el valor final validado en el campo *placa corregida*, utilizado como referencia para los análisis posteriores.

La gestión, edición y validación de los eventos registrados se realizó a través de una interfaz web de administración, ilustrada en la Figura 2, la cual permitió la visualización de eventos, la corrección manual de placas, el filtrado por fechas y placas, así como la clasificación del estado de cada registro. Esta interfaz facilitó la interacción directa del operador con el sistema sin interrumpir el proceso automático de captura y detección.

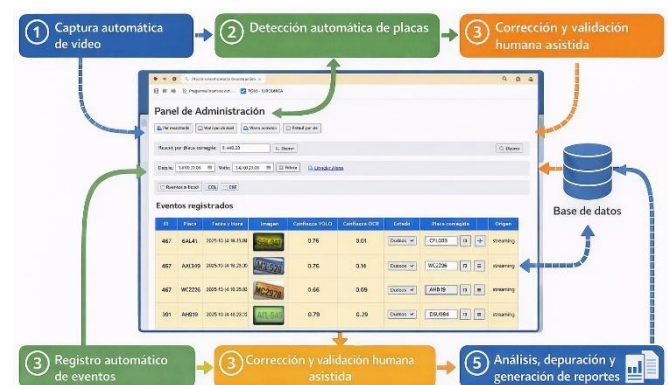


Fig. 2. Panel de administración del sistema.

Todos los eventos fueron almacenados en una base de datos SQLite, incluyendo información temporal, evidencias visuales, niveles de confianza del detector y del OCR, así como el valor de la *placa corregida*. Adicionalmente, el sistema implementó un proceso de depuración temporal, mediante el cual las detecciones consecutivas asociadas a

una misma placa corregida y registradas dentro de un intervalo menor o igual a dos minutos fueron consideradas como un solo evento válido, evitando así la sobreestimación del flujo vehicular real.

Finalmente, el sistema permitió la exportación de los datos depurados en formatos estructurados (Excel, CSV y PDF), asegurando su disponibilidad para el análisis estadístico posterior y la evaluación experimental del prototipo.

3 RESULTADOS

3.1 Resultados del entrenamiento del modelo

El modelo de detección de placas vehiculares fue entrenado durante 100 épocas, evaluándose su desempeño mediante las métricas de precisión (precision), exhaustividad (recall) y mean Average Precision a un umbral de intersección sobre unión de 0.5 (mAP@0.5). Estas métricas permiten analizar tanto la capacidad del modelo para identificar correctamente las placas vehiculares como su desempeño en la localización precisa de las regiones de interés.

Como se observa en la Figura 3, las métricas presentan una rápida mejora durante las primeras épocas de entrenamiento, seguida de una estabilización progresiva conforme avanza el proceso. La precisión alcanzó valores cercanos a 0.98, lo que evidencia una alta proporción de detecciones correctas respecto al total de predicciones realizadas por el modelo. De manera complementaria, el recall se estabilizó alrededor de 0.95, indicando una elevada capacidad para detectar la mayoría de las placas presentes en las imágenes del conjunto de entrenamiento.

Por su parte, la métrica mAP@0.5 mostró un crecimiento sostenido hasta aproximarse a 0.97, reflejando un desempeño robusto en la localización de placas vehiculares bajo el umbral establecido. La convergencia simultánea de las tres métricas sugiere un proceso de aprendizaje estable y consistente, coherente con el comportamiento reportado en modelos de detección basados en aprendizaje profundo cuando el entrenamiento alcanza un punto de estabilización adecuado [12].

En conjunto, estos resultados indican que el modelo alcanza un alto nivel de desempeño en un entorno controlado de entrenamiento, constituyendo una base confiable para su posterior integración y evaluación dentro del sistema de reconocimiento de placas vehiculares operando en condiciones reales.




Fig. 3. Desempeño del modelo durante el entrenamiento.

3.2 Resultados del sistema en operación real

El sistema de reconocimiento de placas vehiculares fue evaluado en condiciones reales de operación durante un periodo continuo de observación, empleando una cámara fija instalada en la única vía de ingreso y salida hacia la zona minera de Pochuanca. Durante este intervalo, el sistema capturó de manera automática eventos vehiculares mediante transmisión de video en tiempo real, generando registros asociados a la detección y almacenamiento de placas vehiculares.

Debido a las características propias del entorno de operación (vía no asfaltada, variaciones significativas de iluminación natural, presencia de polvo en suspensión y diferentes velocidades de tránsito), un mismo vehículo pudo ser detectado múltiples veces mientras permanecía dentro del campo visual de la cámara. Este comportamiento es consistente con lo reportado en estudios previos sobre sistemas de reconocimiento automático de placas vehiculares en escenarios no controlados, donde las detecciones redundantes pueden conducir a una sobreestimación del flujo vehicular si no se aplican mecanismos de depuración adecuados [5], [10].

Con el fin de mitigar este efecto, se implementó un proceso de depuración temporal, considerando como un único evento válido todas las detecciones correspondientes a una misma **placa corregida** registradas dentro de un intervalo menor o igual a dos minutos. Este enfoque se alinea con metodologías empleadas en sistemas de conteo y monitoreo vehicular basados en video, donde la agregación temporal permite reducir duplicidades sin afectar la representatividad del flujo real [10].

Asimismo, el módulo de reconocimiento óptico de caracteres (OCR) presentó limitaciones en la correcta interpretación alfanumérica de las placas bajo condiciones reales de operación. Factores como suciedad en las placas, desgaste físico, desenfoque por movimiento y variaciones de ilumina-

ción afectaron negativamente la fiabilidad del OCR, fenómeno ampliamente documentado en la literatura especializada [5], [11], [12]. En consecuencia, el análisis estadístico se realizó exclusivamente utilizando el campo placa corregida, el cual fue validado manualmente por el operador a partir del recorte generado por el modelo de detección. Este enfoque híbrido, que combina detección automática con validación humana asistida, ha sido identificado como una estrategia eficaz para garantizar la integridad del dato final en sistemas de vigilancia vehicular [4].

La Tabla 1 presenta un resumen de los eventos vehiculares registrados tras aplicar los procesos de depuración temporal y validación manual. Del total de 489 registros capturados automáticamente, se obtuvieron 403 eventos únicos, correspondientes a 134 placas corregidas distintas. La proporción de eventos inicialmente clasificados como dudosos se atribuye principalmente a las condiciones reales de captura y a las limitaciones inherentes del OCR, lo que refuerza la pertinencia del mecanismo de corrección manual incorporado en el sistema.

En conjunto, estos resultados evidencian que el sistema es capaz de registrar de manera continua y confiable el flujo vehicular real en un entorno no controlado, manteniendo la trazabilidad de los eventos y proporcionando datos depurados adecuados para su análisis estadístico posterior. La combinación de detección automática, depuración temporal y validación humana permitió equilibrar eficiencia operativa y calidad de la información, aspectos clave en aplicaciones reales de monitoreo vehicular [4], [5], [12].

Tabla 1.

Resumen de eventos vehiculares depurados según placa corregida

Indicador	Descripción	Valor
Total de registros capturados	Detecciones generadas automáticamente por el sistema	489
Registros depurados	Eventos únicos tras agrupar detecciones ≤ 2 min por placa corregida	403
Placas corregidas únicas	Número de placas únicas identificadas manualmente	134
Eventos válidos	Eventos clasificados como válidos	8
Eventos dudosos	Eventos con ambigüedad visual u OCR	334
Eventos inválidos	Eventos descartados	61

4 DISCUSIÓN

Los resultados obtenidos permiten analizar de manera integral el desempeño del sistema de reconocimiento de placas vehiculares, considerando tanto la etapa de entrenamiento del modelo de detección como su comportamiento durante la

operación en condiciones reales. Durante la fase de entrenamiento, el modelo YOLOv8n alcanzó valores elevados de precisión, recall y mAP@0.5, evidenciando una adecuada capacidad para la detección y localización de placas vehiculares en conjuntos de datos controlados, coherente con el desempeño reportado por detectores de una sola etapa de la familia YOLO en tareas de detección en tiempo real [6], [7], [8]. Adicionalmente, el despliegue del prototipo sobre una plataforma embebida respalda la viabilidad del procesamiento local en el borde (edge), alineándose con enfoques de analítica de video en edge computing orientados a reducir latencia y dependencia de infraestructura centralizada [9], [13].

No obstante, al trasladar el modelo a un entorno real no controlado, se observaron diferencias significativas entre el rendimiento obtenido durante el entrenamiento y el desempeño global del sistema en operación. Factores propios del entorno de captura — como variaciones abruptas de iluminación natural, presencia de polvo en suspensión, vibraciones de la cámara y velocidades variables de los vehículos — influyeron directamente en la calidad visual de las imágenes y, en consecuencia, en las etapas posteriores de procesamiento. Este fenómeno ha sido ampliamente documentado en sistemas de visión artificial desplegados en escenarios reales, donde la variabilidad ambiental introduce desafíos que no siempre están representados en los conjuntos de entrenamiento [4], [10].

En particular, aunque la etapa de detección de placas se mantuvo estable, el módulo de reconocimiento óptico de caracteres (OCR) presentó limitaciones en la correcta interpretación alfanumérica de las placas. La elevada proporción de eventos inicialmente clasificados como dudosos confirma que el OCR constituye uno de los componentes más sensibles del sistema, especialmente en escenarios rurales o no controlados. Este hallazgo concuerda con revisiones clásicas y estudios recientes sobre sistemas de reconocimiento automático de placas vehiculares, donde se identifica al OCR como el principal cuello de botella en términos de precisión global bajo condiciones reales de operación [5], [11], [12].

Ante estas limitaciones, la incorporación de un mecanismo de validación humana asistida permitió garantizar la integridad del dato final utilizado en el análisis estadístico. A diferencia de enfoques completamente automáticos, el esquema híbrido propuesto — basado en detección automática, depuración temporal y corrección manual — se ajusta mejor a escenarios reales donde la calidad visual no puede ser controlada, tal como ha sido sugerido en estudios recientes sobre sistemas de vigilancia vehicular y monitoreo continuo [4].

Asimismo, en contextos de video vigilancia vehicular, un mismo vehículo puede ser detectado múltiples veces mientras permanece dentro del campo visual de la cámara, lo que introduce la necesidad de mecanismos de agrupación y depuración temporal para evitar la sobreestimación del flujo vehicular. Este fenómeno ha sido ampliamente abordado en la literatura sobre seguimiento y conteo de objetos en secuencias de video, donde se destaca la importancia de técnicas de asociación temporal para mantener la consistencia de los

eventos detectados [14]. La estrategia adoptada en este trabajo, basada en la agrupación de detecciones consecutivas dentro de un intervalo temporal definido, es coherente con enfoques utilizados en sistemas de conteo vehicular basados en video, los cuales reportan mejoras significativas en la representatividad de los eventos reales [10].

Finalmente, los resultados obtenidos evidencian la viabilidad del despliegue del sistema sobre hardware de bajo consumo, específicamente una Raspberry Pi 5. A pesar de las restricciones computacionales inherentes a este tipo de plataformas, el sistema logró operar de manera continua, capturando eventos vehiculares y almacenando registros estructurados para su posterior análisis. Este resultado respalda el uso de enfoques de *edge computing* y *edge intelligence* como alternativas eficientes para aplicaciones de monitoreo en zonas con infraestructura limitada o conectividad restringida, tal como se propone en la literatura reciente [9], [15].

5 CONCLUSIONES

El modelo YOLOv8n entrenado para la detección de placas vehiculares presentó un desempeño alto y estable en condiciones controladas, alcanzando valores de precisión cercanos a 0.98, recall alrededor de 0.95 y un mAP@0.5 aproximado de 0.97, lo que evidencia una adecuada capacidad de localización de placas y un proceso de entrenamiento consistente, sin indicios de sobreajuste, conforme a los resultados mostrados en la Sección 3.1.

Durante la operación en un entorno real no controlado, el sistema demostró capacidad para capturar y registrar de forma continua el tránsito vehicular en la vía de acceso a la unidad minera de Pochuanca, generando un total de 489 registros automáticos. Tras aplicar el proceso de depuración temporal y validación manual, estos registros se consolidaron en 403 eventos únicos correspondientes a 134 placas corregidas distintas, reflejando de manera más precisa el flujo vehicular real observado (Sección 3.2).

La etapa de detección de placas se mantuvo robusta durante la operación real, incluso bajo condiciones adversas como variaciones de iluminación, presencia de polvo y diferentes velocidades de tránsito, lo que confirma que el desempeño del detector entrenado se trasladó de forma efectiva desde el entorno de entrenamiento hacia el escenario de aplicación práctica.

El reconocimiento óptico de caracteres (OCR) constituyó el principal factor limitante del sistema, evidenciado por la elevada proporción de eventos clasificados inicialmente como dudosos. Esta situación justificó la incorporación del campo *placa_corregida* y del mecanismo de validación humana asistida, el cual permitió asegurar la consistencia y confiabilidad de los datos utilizados en el análisis estadístico, tal como se refleja en los resultados operativos.

El proceso de depuración temporal basado en un intervalo

menor o igual a dos minutos por placa corregida resultó fundamental para evitar la sobreestimación de eventos, permitiendo consolidar múltiples detecciones consecutivas de un mismo vehículo en un solo evento válido. Esta estrategia mejoró la representatividad de los resultados respecto al flujo vehicular real registrado por el sistema.

La implementación del sistema sobre una plataforma Raspberry Pi 5 demostró la viabilidad de ejecutar aplicaciones de visión artificial en hardware de bajo consumo, logrando una operación continua y estable sin requerir infraestructura de cómputo centralizada, lo que resulta adecuado para contextos mineros comunitarios con limitaciones tecnológicas.

Finalmente, los resultados experimentales evidencian que el prototipo desarrollado constituye una herramienta funcional de apoyo al control vehicular, capaz de automatizar la captura de eventos y facilitar el análisis posterior de la información. No obstante, el sistema se plantea como un complemento al método tradicional actualmente en uso, constituyendo una base técnica y metodológica sólida para futuras evaluaciones orientadas a su adopción institucional progresiva y a la optimización integral del control de acceso vehicular en contextos similares.

AGRADECIMIENTOS

A la comunidad de Pochuanca, en la provincia de Aymaraes, por permitir el acceso a la zona minera y brindar las facilidades necesarias para la instalación de la cámara y la evaluación del prototipo de reconocimiento de placas vehiculares en condiciones reales de operación. La colaboración y disposición de la comunidad fueron fundamentales para la recolección de datos y la validación del sistema en un entorno no controlado.

REFERENCIAS

- [1] K. T. Islam *et al.*, "A Vision-Based Machine Learning Method for Barrier Access Control Using Vehicle License Plate Authentication," *Sensors*, vol. 20, no. 12, p. 3578, 2020, doi: 10.3390/s20123578.
- [2] F. Ullah *et al.*, "Barrier Access Control Using Sensors Platform and Vehicle License Plate Characters Recognition," *Sensors*, vol. 19, no. 13, p. 3015, Jul. 2019, doi: 10.3390/s19133015.
- [3] M. Mohandes, M. Deriche, H. Ahmadi, M. Kousa, and A. Balghonaim, "An Intelligent System for Vehicle Access Control using RFID and ALPR Technologies," *Arab. J. Sci. Eng.*, vol. 41, no. 9, pp. 3521–3530, Sep. 2016, doi: 10.1007/s13369-016-2136-0.
- [4] S. Ay, "Vehicle Detection And Vehicle Tracking Applications On Traffic Video Surveillance Systems: A systematic literature review," *Int. J. Comput. Exp. Sci. Eng.*, vol. 10, no. 4, Nov. 2024, doi: 10.22399/ijcesen.629.
- [5] S. Du, M. Ibrahim, M. Shehata, and W. Badawy, "Automatic License Plate Recognition (ALPR): A State-of-the-Art Review," *IEEE Trans. Circuits Syst. Video Technol.*,

- vol. 23, no. 2, pp. 311–325, Feb. 2013, doi: 10.1109/TCSVT.2012.2203741.
- [6] J. Redmon and A. Farhadi, “YOLOv3: An Incremental Improvement,” 2018, *arXiv*. doi: 10.48550/ARXIV.1804.02767.
- [7] A. Bochkovskiy, C.-Y. Wang, and H.-Y. M. Liao, “YOLOv4: Optimal Speed and Accuracy of Object Detection,” Apr. 23, 2020, *arXiv*: arXiv:2004.10934. doi: 10.48550/arXiv.2004.10934.
- [8] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA: IEEE, Jun. 2016, pp. 779–788. doi: 10.1109/CVPR.2016.91.
- [9] S. Deng, H. Zhao, W. Fang, J. Yin, S. Dustdar, and A. Y. Zomaya, “Edge Intelligence: The Confluence of Edge Computing and Artificial Intelligence,” *IEEE Internet Things J.*, vol. 7, no. 8, pp. 7457–7469, Aug. 2020, doi: 10.1109/JIOT.2020.2984887.
- [10] Z. Dai *et al.*, “Video-Based Vehicle Counting Framework,” *IEEE Access*, vol. 7, pp. 64460–64470, 2019, doi: 10.1109/ACCESS.2019.2914254.
- [11] N. Plavac, S. A. Amirshahi, M. Pedersen, and S. Triantaphillidou, “Performance of Automatic License Plate Recognition Systems on Distorted Images,” *J. Imaging Sci. Technol.*, vol. 68, no. 6, pp. 1–16, Nov. 2024, doi: 10.2352/J.ImagingSci.Technol.2024.68.6.060401.
- [12] H. Li, P. Wang, and C. Shen, “Toward End-to-End Car License Plate Detection and Recognition With Deep Neural Networks,” *IEEE Trans. Intell. Transp. Syst.*, vol. 20, no. 3, pp. 1126–1136, Mar. 2019, doi: 10.1109/TITS.2018.2847291.
- [13] X. Ran, H. Chen, X. Zhu, Z. Liu, and J. Chen, “DeepDecision: A Mobile Deep Learning Framework for Edge Video Analytics,” in *IEEE INFOCOM 2018 - IEEE Conference on Computer Communications*, Honolulu, HI: IEEE, Apr. 2018, pp. 1421–1429. doi: 10.1109/INFOCOM.2018.8485905.
- [14] N. Wojke, A. Bewley, and D. Paulus, “Simple online and realtime tracking with a deep association metric,” in *2017 IEEE International Conference on Image Processing (ICIP)*, Beijing: IEEE, Sep. 2017, pp. 3645–3649. doi: 10.1109/ICIP.2017.8296962.
- [15] A. Bewley, Z. Ge, L. Ott, F. Ramos, and B. Upcroft, “Simple online and realtime tracking,” in *2016 IEEE International Conference on Image Processing (ICIP)*, Phoenix, AZ, USA: IEEE, Sep. 2016, pp. 3464–3468. doi: 10.1109/ICIP.2016.7533003.