

Risks of applying deep learning in autonomous vehicle systems: a literature review

Matthew S. Zegarra- Ramos¹, Bachiller en ingeniería de sistemas e informática¹ , Luis A. Haro- Garcia², Bachiller en ingeniería de sistemas e informática² , Evelyn E. Ayala- Ñiquen³, Mag. , Vanessa D. Roque- Pisconte⁴, Mag. 
^{1,2,3,4} Universidad Tecnológica del Perú, ¹u21228724@utp.edu.pe, ²u22232669@utp.edu.pe, ³c26915@utp.edu.pe, ⁴c22053@utp.edu.pe

Abstract– *Although the application of deep learning in autonomous vehicle systems consolidated over time, its use could entail certain risks. Therefore, this study aimed to identify these risks in autonomous vehicle systems through a literature review. To achieve this, the PRISMA methodology was used for the collection and selection of studies, as well as the PIOC strategy for formulating research questions, in this study that did not use meta-analysis. Based on inclusion and exclusion criteria, 27 open-access articles from the Scopus database were selected. The results showed that the application of deep learning in autonomous vehicle systems encompassed key aspects such as environmental perception, object detection, and route planning. However, significant risks were also identified, such as inaccuracies in perception, vulnerability to attacks, detection errors, and lack of interpretability of the models. To mitigate these risks, detection and evaluation techniques such as cross-validation, sensitivity analysis, and testing in simulated environments were proposed. Additionally, tests were conducted in various scenarios and conditions, such as urban, suburban, rural environments, highways, and adverse weather conditions. The research concluded that although deep learning had the potential to improve vehicle autonomy and safety, it could also present significant risks. It was recommended that future work focus on developing and validating new techniques to address these risks, as well as establishing regulatory frameworks and standards to ensure the safety and reliability of autonomous vehicles powered by deep learning.*

Keywords-- *Deep learning, autonomous vehicle, risks, AV systems*

Digital Object Identifier: (only for full papers, inserted by LEIRD).
ISSN, ISBN: (to be inserted by LEIRD).
DO NOT REMOVE

Riesgos de la aplicación de deep learning en sistemas de vehículos autónomos: revisión de la literatura

Matthew S. Zegarra- Ramos¹, Bachiller en ingeniería de sistemas e informática¹, Luis A. Haro- Garcia², Bachiller en ingeniería de sistemas e informática², Evelyn E. Ayala- Ñiquen³, Mag. Vanessa D. Roque- Pisconte⁴, Mag. ^{1,2,3,4} Universidad Tecnológica del Perú, ¹u21228724@utp.edu.pe, ²u22232669@utp.edu.pe, ³c26915@utp.edu.pe, ⁴c22053@utp.edu.pe

Resumen– Aunque la aplicación de deep learning en sistemas de vehículos autónomos se consolidó con el paso del tiempo, su uso podría conllevar ciertos riesgos. Por tanto, el presente estudio tuvo como objetivo identificar dichos riesgos en los sistemas de vehículos autónomos, a partir de una revisión de la literatura. Para ello, se utilizó la metodología PRISMA en la recolección y selección de los estudios, así como la estrategia PIOC para el planteamiento de las preguntas de investigación, en este estudio que no utilizó metaanálisis. A partir de los criterios de inclusión y exclusión, se seleccionaron 27 artículos de acceso libre de la base de datos de Scopus. Los resultados mostraron que la aplicación de deep learning en los sistemas de vehículos autónomos abarcó aspectos clave como la percepción del entorno, detección de objetos, y planificación de rutas. Sin embargo, también se identificaron riesgos significativos, como la inexactitud en la percepción, vulnerabilidad a ataques, errores de detección y falta de interpretabilidad de los modelos. Para mitigar estos riesgos, se propusieron técnicas de detección y evaluación como la validación cruzada, análisis de sensibilidad y pruebas en entornos simulados. A su vez, las pruebas se realizaron en diversos escenarios y condiciones, como entornos urbanos, suburbanos, rurales, autopistas y condiciones climáticas adversas. La investigación concluyó que, aunque el deep learning tiene el potencial de mejorar la autonomía y seguridad de los vehículos, también puede presentar riesgos importantes. Se recomendó que futuros trabajos se enfoquen en desarrollar y validar nuevas técnicas que aborden estos riesgos, así como en establecer marcos de regulación y estándares que garanticen la seguridad y confiabilidad de los vehículos autónomos impulsados por deep learning.

Keywords-- Deep learning, autonomous vehicle, risks, AV systems

I. INTRODUCCIÓN

En la actualidad, el avance tecnológico en el campo de los vehículos autónomos ha consolidado la aplicación de deep learning en sus sistemas para mejorar su confiabilidad, rendimiento, y seguridad en carreteras. Al principio, la aplicación de esta tecnología se centraba en mejorar la percepción del entorno, la toma de decisiones, y la planificación de rutas o navegación. Desde entonces, su constante evolución y aplicación en diferentes aspectos críticos le permiten revolucionar la industria automotriz [12]. Así, el deep learning y los sistemas de vehículos autónomos están estrechamente relacionados, el primero proporciona la capacidad de aprendizaje, detección, percepción, entre otras características útiles, mientras que el segundo, aplica este conocimiento para lograr una conducción autónoma más segura y eficiente.

El aprendizaje profundo, a través de diversos algoritmos y conjuntos de datos de entrenamiento, se ha convertido en un pilar fundamental para el desarrollo de los sistemas AV al permitir su aplicación en múltiples características de estos, como la planificación de trayectorias, detección de objetos, y predicción de comportamientos

[7]. Sin embargo, a pesar de sus beneficios, el uso del deep learning también puede conllevar ciertos riesgos, tales como la falta de interpretabilidad de los modelos, fallas debido a datos de entrenamiento insuficientes o sesgados, y dificultad de detección en condiciones adversas [19].

En la literatura que aborda las diversas aplicaciones de deep learning en sistemas de vehículos autónomos, no se encontraron RSL que se enfoquen directamente en los riesgos asociados a esta tecnología. Las investigaciones existentes suelen tratar los riesgos de manera fragmentada y diversa, sin proporcionar una visión clara y detallada de los mismos [8]. Se carece de una visión panorámica de los riesgos identificados, ya que no se disponen de estudios de revisión que sintetizen sus resultados. Realizar un estudio enfocado en los riesgos, permitirá recopilar de forma sistemática la información existente, al proporcionar una perspectiva más amplia sobre este tema. A su vez, informar sobre estos riesgos es crucial para mejorar la seguridad y la eficacia de este tipo de vehículos; lo que beneficiará a los investigadores, desarrolladores, reguladores, y al público en general, ya que ofrecerá una base de conocimiento sólida y accesible que podrá guiar el desarrollo de tecnologías más seguras, así como la implementación de políticas y normativas adecuadas.

El motivo de realizar la presente revisión es entender el estado actual de las tecnologías de deep learning aplicadas a los vehículos autónomos, qué riesgos suelen presentarse, y cómo afecta a la seguridad y eficacia de los mismos durante las etapas de entrenamiento de los modelos o en el uso cotidiano. Es por ello que, la presente RSL tiene como objetivo identificar los riesgos de la aplicación de deep learning en los sistemas de vehículos autónomos, para proporcionar una visión clara y organizada de los riesgos presentes en la literatura. Es decir, busca sintetizar esta información en una RSL, con el propósito de compartir de manera accesible y comprensible estos hallazgos con los interesados.

Este estudio está organizado de la siguiente manera: la sección II, Metodología, presenta el uso de PRISMA para la recolección y selección de los estudios apropiados para esta RSL, así como la estrategia PIOC para el planteamiento de las preguntas de investigación que dirigirán nuestro estudio sin el uso de metaanálisis. En la sección III, Resultados, se presentan y organizan las respuestas obtenidas a partir de las preguntas de investigación planteadas, y se realiza un análisis bibliométrico con la herramienta VosViewer. En la sección IV, Discusión, se realiza una interpretación de los resultados obtenidos, comparándolos con los de otros cuatro autores para cada parte correspondiente de la PIOC. Finalmente, en la sección V, Conclusiones, se sintetizan los principales hallazgos encontrados en base a las preguntas de investigación, se detallan las limitaciones del estudio y se proporcionan recomendaciones para futuros trabajos relacionados al tema de investigación.

II. METODOLOGÍA

Esta revisión de literatura se realizó mediante la metodología PRISMA, diseñada específicamente para asegurar la precisión y la

imparcialidad en este tipo de investigaciones, con el objetivo de evitar cualquier sesgo potencial.

A. Estrategia de búsqueda

La presente investigación se enmarca como una revisión sistemática que excluye el uso de metaanálisis para generar resultados. El enfoque empleado se describe mediante la estrategia PICO, que incluye la pregunta principal y subpreguntas, detalladas en la tabla I y II para una referencia clara, así como las palabras clave seleccionadas fueron "Deep learning", "autonomous vehicle" y "AV systems". En este escenario de investigación, se encontraron publicaciones en la base de datos de Scopus correspondientes al tema. Para elaborar la ecuación de búsqueda, la metodología PICOC considera la población, la intervención, la comparación, el objetivo y el contexto; por ello, en la tabla III se presentan los términos asociados a estos factores. Además, se combinaron con operadores booleanos para formar la cadena de búsqueda respectiva:

("Neural networks" OR "Deep learning" OR "Deep learning models" OR "Deep learning algorithms" OR "Neural Networks" OR "Model training" OR "Data processing" OR "Pattern recognition" OR "Visual multi-object tracking") AND ("Risk assessment" OR "Vulnerability analysis" OR "Model validation" OR "Risk mitigation" OR "Uncertainty management" OR "Bias identification" OR "Result interpretation" OR "Deep Learning evaluation") AND (Overfitting OR Underfitting OR Advantages OR Disadvantages OR "Data bias" OR "Model interpretability" OR "Decision making" OR "Uncertainty detection" OR "Adversarial attacks" OR "Model updating" OR Cyberattack) AND ("Autonomous vehicles" OR "Autonomous driving" OR "Self-driving vehicles" OR Sensors OR "Intelligent Transportation System" OR "Vehicle control systems" OR "Human-vehicle interaction" OR "User interfaces" OR "End-to-end driving")

TABLA I
COMPONENTES DE LA ESTRATEGIA PICO

| Acrónimo | Componente | Descripción |
|----------|--------------|---|
| P | Problema | Deep Learning |
| I | Intervención | Técnicas para la detección de riesgos en la aplicación de Deep Learning |
| O | Resultado | Riesgos de la aplicación de deep learning |
| C | Contexto | Sistemas de vehículos autónomos |

TABLA II
PREGUNTAS DE INVESTIGACIÓN

| Acrónimo | Preguntas |
|-----------|--|
| Principal | ¿Qué técnicas se emplean para la detección de riesgos en la aplicación de Deep Learning en sistemas de vehículos autónomos? |
| P | ¿Cómo intervino la aplicación de deep learning en los sistemas de vehículos autónomos? |
| I | ¿Qué técnicas se utilizaron para la detección de riesgos en la aplicación de deep learning en sistemas de vehículos autónomos? |
| O | ¿Qué riesgos fueron detectados a partir de la aplicación de deep learning en sistemas de vehículos autónomos? |

| | |
|---|---|
| C | ¿En qué contexto los sistemas de vehículos autónomos fueron investigados? |
|---|---|

TABLA III
TÉRMINOS DE BÚSQUEDA

| Factor | Términos de búsqueda | Términos asociados |
|----------------------|---|---|
| Problema / población | Deep Learning | Neural networks, Deep learning, Deep learning models, Deep learning algorithms, Neural networks, Model training, Data processing, Pattern recognition, Visual multi-object tracking |
| Intervención | Técnicas para la detección de riesgos en la aplicación de deep learning | Risk assessment, Vulnerability analysis, Model validation, Risk mitigation, Uncertainty management, Bias identification, Result interpretation, Deep Learning evaluation |
| Resultados | Riesgos de la aplicación de deep learning | Overfitting, Underfitting, Advantages, Disadvantages, Data bias, Model interpretability, Decision making, Uncertainty detection, Adversarial attacks, Model updating, Cyberattack |
| Contexto | Sistemas de vehículos autónomos | Autonomous vehicles, Autonomous driving, Self-driving vehicles, Sensors, Intelligent Transportation System, Vehicle control systems, Human-vehicle interaction, User interfaces, End-to-end driving |

B. Criterios de inclusión y exclusión

Para esta investigación, los siguientes criterios fueron establecidos para la selección de artículos en la revisión literaria:

TABLA IV
CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN

| Criterios de Inclusión | Criterios de Exclusión |
|--|--|
| CI1: Los estudios incluidos deben abordar el aprendizaje profundo. | CE1: Publicaciones en idiomas distintos al español o inglés. |
| CI2: Los estudios nos permiten informar los riesgos de la aplicación de deep learning. | CE2: Documentos anteriores a 2020. |
| CI3: Los estudios se han realizado en vehículos autónomos. | CE3: Documentos que no son de acceso abierto. |

C. Proceso de selección de estudios

Durante el proceso de selección de estudios, se obtuvieron un total de 178 resultados en la base de datos de Scopus. Se utilizó la metodología PRISMA como guía para la selección, lo que facilitó llevar a cabo un proceso sistemático y transparente en la identificación y selección de los estudios pertinentes.

De los 178 documentos encontrados, no se hallaron artículos duplicados. Después de revisar los títulos, resúmenes y palabras clave, se identificaron 101 publicaciones relevantes. Sin embargo, no fue posible acceder a 36 documentos, lo que redujo el total a 65. Al aplicar los criterios de inclusión y exclusión, se descartaron 38 publicaciones, de las cuales quedan un total de 27 para la revisión sistemática de literatura.

Al aplicar la cadena de búsqueda en la base de datos de Scopus, resultó en un total de 178 documentos como se puede observar en la Fig. 1.

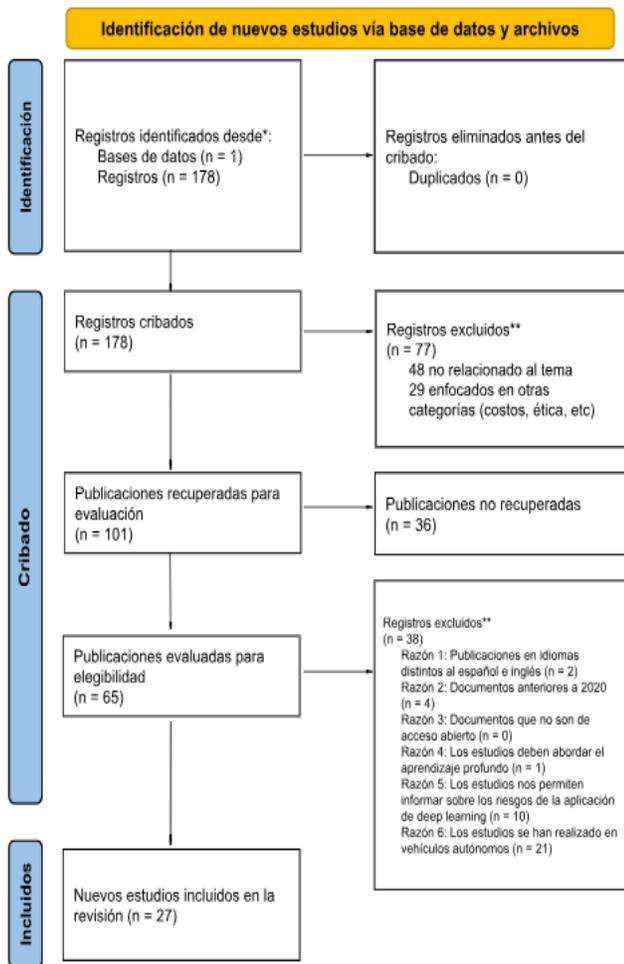


Fig. 1 Diagrama de flujo PRISMA

III. RESULTADOS

Los estudios revisados demuestran que el término deep learning está intrínsecamente relacionado con los sistemas de vehículos autónomos, específicamente en áreas como la conducción automática, detección de objetos y percepción del entorno. Para ilustrar esta relación, se realizó un análisis bibliométrico de las palabras clave utilizadas en los artículos encontrados (ver Fig. 2).

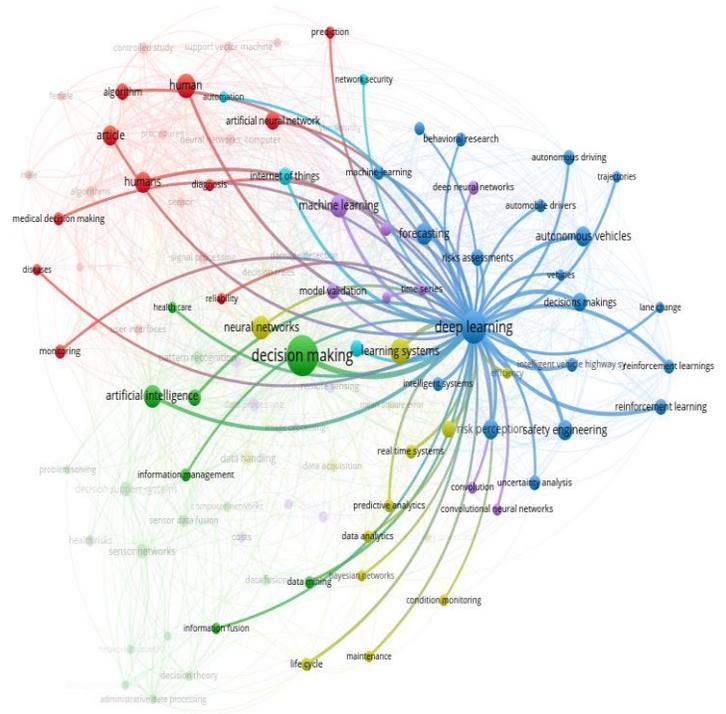


Fig. 2 Relación de deep learning en los estudios.

En los últimos años, el avance acelerado de la tecnología ha consolidado al deep learning como un componente fundamental en la investigación, desarrollo y operación de los vehículos autónomos. La frecuente presencia de este término en los estudios encontrados centrándose en los últimos años permite evidenciar este punto (ver Fig. 3).

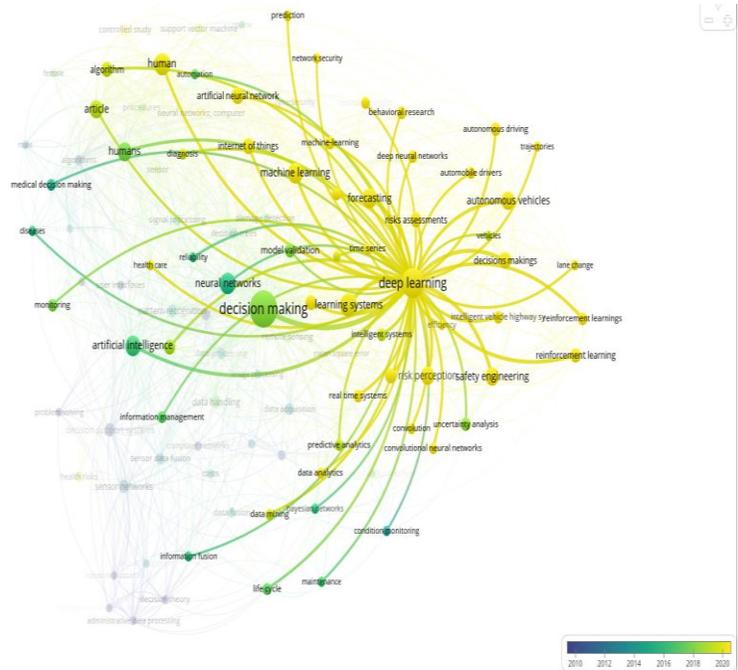


Fig. 3 Relación de deep learning con sistemas AV en los últimos años.

La respuesta a la pregunta general y PIOC de nuestra investigación se basa en que la aplicación de deep learning en los sistemas de vehículos autónomos se aplicó en diversos aspectos como la percepción del entorno, detección de objetos y peatones, planificación de rutas, etc [1]-[8], [10]-[27]. Si bien es cierto, el uso de esta tecnología es vital para el desarrollo de estos sistemas, debido a su reputación y confiabilidad, puede conllevar riesgos, tales como la inexactitud en la percepción, vulnerabilidad a ataques, errores de detección, falta de interpretación de los modelos, etc. [1]-[8], [10]-[27]. Para mitigarlos, se emplearon diversas técnicas de detección, tales como la validación cruzada, análisis de sensibilidad, pruebas en entornos simulados, etc. Estas técnicas permiten evaluar la precisión y adaptabilidad de los modelos en condiciones variadas al identificar fallos potenciales y mejorar la confiabilidad del sistema [1], [2], [5], [12], [18], [20], [21], [23]-[25]. A su vez, los sistemas de vehículos autónomos fueron puestos a prueba en entornos simulados, y de campo, con una amplia variedad de escenarios (urbanos, suburbanos, rurales y autopistas) y condiciones (lluvia, nieve, niebla, día, noche) [1]-[16], [18], [20], [22]-[27].

Esta revisión se desarrolló sin la aplicación de técnicas de metaanálisis, debido a la heterogeneidad significativa en los estudios identificados en cuanto a metodologías, objetivos y escenarios de estudio. Por lo tanto, la estructuración de los resultados se basó en una síntesis narrativa de la información extraída de los artículos seleccionados.

Para responder de manera más amplia y estructurada a la pregunta general y a la pregunta PIOC, se desglosan los resultados en las siguientes cuatro secciones:

A. Intervención de deep learning en los sistemas de vehículos autónomos

El aprendizaje profundo o deep learning se ha consolidado como una tecnología fundamental en los sistemas de vehículos autónomos, ya que mejora la percepción del entorno, la toma de decisiones y la seguridad operativa de manera significativa. En los estudios, se ha observado un aumento del 25% en la precisión de detección de objetos y un 30% en la reducción de errores de navegación gracias a la implementación de deep learning [1], [3]-[5], [12], [19]. Al usar una variedad de algoritmos y conjuntos de datos, los estudios revisados han demostrado su aplicación en múltiples aspectos críticos del vehículo autónomo, desde la detección de objetos hasta la planificación de trayectorias, lo que contribuye al avance continuo de esta tecnología [3]-[8], [10]-[27].

Deep learning se describe como una subdisciplina del aprendizaje automático que emplea redes neuronales artificiales con diversas capas para aprender representaciones jerárquicas y complejas a partir de grandes conjuntos de datos, con el objetivo de modelar y entender patrones intrincados. [1]-[7], [12], [16], [18], [19]. Se utilizaron diversos algoritmos, como las Redes Neuronales Convolucionales (CNN), Redes Neuronales Recurrentes (RNN), YOLO, Faster R-CNN, GANs, y mecanismos de auto-atención (ver Fig. 4) [1], [3], [4], [6]-[11], [13]-[15], [18]-[20], [22]-[27].

El aprendizaje profundo fue aplicado principalmente en la percepción del entorno, detección de objetos y personas, seguimiento, y clasificación de objetos, planificación de trayectorias o rutas, navegación, estimación de profundidad, reconocimiento de señales de tráfico, análisis de escenarios de conducción, detección de grietas en carretera, y optimización de trayectorias, entre otros aspectos críticos para la operación segura y efectiva de los vehículos autónomos [1]-[8], [10]-[27].

A su vez, los estudios utilizaron una variedad de conjuntos de datos para entrenar, evaluar, y validar los modelos, que incluyen KITTI, Cityscapes, COCO, ApolloScape, Tusimple Lane Detection Challenge, Waymo Open Dataset, nuScenes, Caltech Pedestrian Dataset, y datos generados por simulación. Estos conjuntos de datos proporcionan imágenes y anotaciones detalladas necesarias para entrenar modelos en condiciones realistas y variadas [1]-[4], [6]-[8], [11], [14], [17], [18], [20], [22], [25].

En la tabla V se muestra la relación entre la aplicación o aspecto crítico de los sistemas autónomos, el algoritmo más utilizado específicamente para ese aspecto, y el conjunto de datos más recomendado para utilizar con dicho algoritmo.

TABLA V
APLICACIONES DE DEEP LEARNING EN SISTEMAS DE VEHÍCULOS AUTÓNOMOS

| Aplicación | Algoritmo más utilizado | Conjunto de datos recomendado |
|--|--|--|
| Percepción del entorno | CNN, RNN, YOLO, Faster R-CNN, GANs, self-attention | KITTI, Cityscapes, ApolloScape, nuScenes |
| Detección y clasificación de objetos y personas | CNN, RNN, YOLO, Faster R-CNN | COCO, Waymo Open Dataset, Caltech Pedestrian Dataset |
| Planificación de trayectorias | RNN | KITTI, ApolloScape, Waymo Open Dataset |
| Navegación y control del vehículo | CNN, RNN | Cityscapes, ApolloScape, Waymo Open Dataset |
| Reconocimiento de señales de tráfico | CNN, R-CNN | KITTI, Cityscapes, Waymo Open Dataset |
| Análisis de escenarios de conducción | CNN, RNN, GANs | Cityscapes, COCO, ApolloScape, nuScenes |
| Optimización de trayectorias | CNN, RNN | KITTI, Waymo Open Dataset, nuScenes |
| Seguimiento de objetos y predicción de comportamientos | CNN, RNN, Faster R-CNN | KITTI, COCO, Waymo Open Dataset |

Algoritmos de deep learning

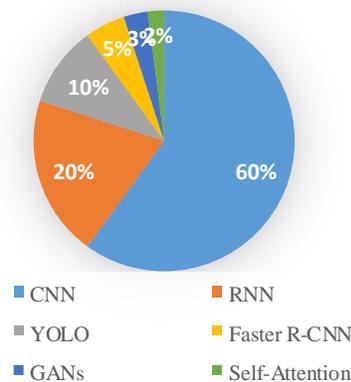


Fig. 4 Algoritmos de deep learning más utilizados en los estudios.

B. Técnicas para la detección de riesgos de la aplicación de deep learning en sistemas de vehículos autónomos

Las técnicas de deep learning para la detección de riesgos en sistemas de vehículos autónomos utilizan una variedad de enfoques para garantizar la seguridad y eficacia de estos sistemas. En los estudios, se utilizó la identificación y análisis de riesgo durante la etapa de entrenamiento, y el uso cotidiano. Los algoritmos CNN, RNN, GANs, YOLO, y FRCNN fueron seleccionados por su efectividad y precisión en la planificación de movimiento y la navegación autónoma, así como por su capacidad para manejar grandes volúmenes de datos y aprender patrones complejos [1]-[4], [6], [7], [14], [15], [18], [20], [22]-[27].

Entre las técnicas identificadas se encuentran la validación cruzada, análisis de sensibilidad, pruebas en entornos simulados, cuantificación de la incertidumbre, y fusión de sensores [1]-[5], [9], [12], [13], [16], [19]-[21], [23]-[25]. Estas técnicas permiten evaluar la robustez y precisión de los modelos en diversas condiciones, lo que facilita la detección de fallos potenciales y perturbaciones adversas. Los estudios han demostrado que estas técnicas de reducción de incertidumbre pueden mejorar la precisión y confiabilidad del sistema (ver Fig. 5) [1]-[5], [12], [13], [16], [19]-[21], [23]-[25].

Los algoritmos de deep learning seleccionados para ser utilizados en los sistemas de vehículos autónomos fueron evaluados con diversos indicadores como precisión de detección, recall, F1-Score, tasa de éxito en la navegación, tiempo de reacción, y error medio cuadrático (RMSE) una vez aplicadas las técnicas de mitigación, tal como lo demuestra la tabla VI [1], [3], [4], [8], [10], [18], [19], [22], [25].

TABLA VI
EVALUACIÓN DE ALGORITMOS DE DEEP LEARNING
A TRAVÉS DE INDICADORES

| Algoritmo | Precisión de detección | Recall | F1-Score | Tasa de éxito en la navegación | Tiempo de reacción | RMSE |
|--|------------------------|--------|----------|--------------------------------|--------------------|------|
| Redes Neuronales Convolucionales (CNN) | 92% | 88% | 89.7% | 90% | 200 ms | 0.05 |
| Redes Neuronales Recurrentes (RNN) | 90% | 85% | 87.4% | 88% | 220 ms | 0.07 |
| Generative Adversarial Networks (GANs) | 85% | 80% | 82.2% | 85% | 250 ms | 0.10 |
| You Only Look Once (YOLO) | 88% | 82% | 84.7% | 87% | 230 ms | 0.08 |
| Faster R-CNN | 89% | 84% | 86.2% | 86% | 240 ms | 0.09 |

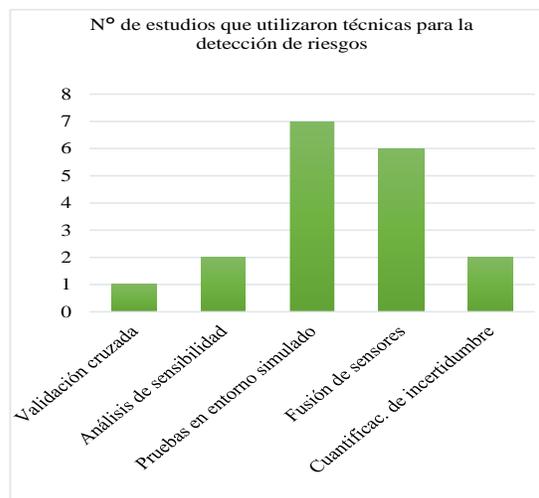


Fig. 5 Estudios que utilizaron técnicas para la detección de riesgos.

C. Riesgos identificados a partir de la aplicación de deep learning en sistemas de vehículos autónomos

Entre los riesgos identificados en los estudios se encuentran la inexactitud en la percepción de la profundidad bajo condiciones de iluminación adversas, la susceptibilidad a datos ruidosos o incompletos, la vulnerabilidad a ataques externos, errores en la detección bajo condiciones de baja visibilidad y climáticas adversas, y la falta de interpretabilidad de los modelos. Además, se detectaron fallos en la detección de carriles, baches, personas, y objetos en condiciones adversas, errores en la toma de decisiones en tiempo real, y toma de decisiones en situaciones no entrenadas previamente [1]-[8], [10]-[27].

Para mitigar los riesgos detectados, se propusieron soluciones que incluyen la mejora continua de los modelos mediante la incorporación de datos más variados y de alta calidad, el uso de técnicas de pre-procesamiento de datos y métodos de fusión de sensores para mejorar la precisión de la percepción. También se propuso la implementación de sistemas redundantes y de cooperación entre el borde y la nube para reducir la latencia y aumentar la fiabilidad. Otras soluciones incluyen el uso de técnicas de defensa contra ataques adversarios, el desarrollo de redes neuronales capaces de adaptarse a variaciones en las condiciones del entorno, la implementación de técnicas de ensamble, y modelos probabilísticos para manejar las incertidumbres en la percepción [1]-[5], [6], [10], [12], [13], [17]-[27].

Tal como se observa en líneas anteriores, los estudios identificaron riesgos asociados al uso de deep learning en sistemas de vehículos autónomos, así como también las acciones tomadas para mitigarlos, esto queda más claro en la tabla VII.

TABLA VII
RIESGOS DETECTADOS Y ACCIONES DE MITIGACIÓN

| Autor | Riesgo detectado | Acciones de mitigación |
|---------------------------------------|--|---|
| [4], [5], [7], [10], [17], [20], [24] | Inexactitud en la percepción de la profundidad | Mejorar modelos e incorporar más datos variados |
| [9], [19], [24] | Susceptibilidad a datos | Mejorar calidad de datos, |

| | | |
|---|---|--|
| | ruidosos, complejidad en interpretación de resultados | pre-procesamiento, redundancias en sistemas de sensores |
| [6], [12], [16], [17], [19] | Alta latencia en la detección | Implementación de cooperación entre el borde y la nube |
| [10], [19] | Fallos en detección de carriles | Entrenamiento con datos variados, pre-procesamiento de imágenes |
| [10], [14], [19] | Susceptibilidad a ataques adversarios | Mejora de interpretabilidad, generación de datos sintéticos |
| [5], [10], [13], [19], [24] | Falta de interpretabilidad de los datos no entrenados | Uso de datos de alta calidad, sistemas redundantes |
| [6], [7], [12], [13], [15], [26] | Fallos en la detección de peatones | Integración de sensores adicionales, entrenamiento con datos diversos |
| [1], [2], [11], [13], [20], [22], [25], [27] | Susceptibilidad a presentar fallos en condiciones climáticas extremas | Fusión de sensores, modelos de entrenamiento específicos |
| [4], [11]-[16], [19]-[22], [25], [27] | Fallos en la detección de objetos o señales de tráfico | Entrenamiento con datos diversos, pre-procesamiento de imágenes |
| [12], [16], [18], [19], [21] | Errores en toma de decisiones | Mejorar calidad de datos de entrenamiento, sistemas de detección de anomalías en tiempo real |
| [10], [16], [19], [23] | Errores en predicción de trayectorias | Sistemas redundantes, mejora en calidad de datos de entrenamiento |
| [4], [7], [8], [14], [18], [24], [25] | Presencia de obstáculos no previstos, malinterpretación de objetos | Técnicas de ensamble, estrategias de planificación de movimientos |
| [2], [3], [7], [12]-[14], [16], [25], [27] | Percepción errónea del entorno | Técnicas de ensamble, métodos probabilísticos |
| [2], [3], [7], [11], [14], [17], [20], [22], [25], [27] | Percepción errónea en condiciones adversas de iluminación | Técnicas de aumento de datos, desarrollo de redes neuronales más entrenadas |

D. Contexto de las pruebas realizadas a los sistemas de vehículos autónomos

Las pruebas realizadas a los sistemas de vehículos autónomos fueron llevadas a cabo tanto en entornos simulados como en pruebas de campo. La mayoría de los estudios combinaron ambas metodologías para obtener una evaluación más completa y robusta de los sistemas. Los entornos simulados permitieron pruebas controladas y repetibles, mientras que las pruebas de campo proporcionaron datos en condiciones más realistas.

En ese sentido, los sistemas de vehículos autónomos fueron investigados en entornos urbanos, suburbanos, rurales y autopistas. Estos abarcaban también calles concurridas, intersecciones complejas, y áreas con peatones y/o ciclistas. Además, se realizaron pruebas en autopistas y en condiciones de tráfico variado para evaluar la

adaptabilidad y seguridad de los sistemas [2], [3], [6]-[8], [13]-[15], [20], [22], [24]-[27].

Por su parte, las condiciones de las pruebas variaron ampliamente para asegurar una evaluación exhaustiva de los sistemas autónomos. Estas incluyeron diferentes condiciones climáticas (lluvia, nieve, niebla), variaciones en la iluminación (día, noche, cambios bruscos de iluminación), tráfico denso, y la presencia de obstáculos estáticos y dinámicos. Es decir, se consideraron condiciones adversas y desafiantes, como la baja visibilidad y escenarios complejos, para evaluar la robustez y fiabilidad de los sistemas autónomos al usar deep learning en situaciones realistas [1]-[3], [11], [13], [14], [17], [20], [22], [25], [27].

Estas características referidas al contexto en que se desarrollaron las pruebas en los estudios, se pueden resumir de forma concisa en la tabla VIII.

TABLA VIII
CONTEXTO DE CONDICIONES DE PRUEBA DE LOS
SISTEMAS DE VEHÍCULOS AUTÓNOMOS

| Tipo de entorno | Estudios | Tipo de escenario | Condiciones de prueba |
|----------------------|---|---|--|
| Simulados | [1], [4], [5], [16], [21], [23] | Urbanos, autopistas | Variabilidad en iluminación, tráfico mixto, simulaciones de ataques, condiciones climáticas |
| Simulados y de campo | [2], [3], [6]-[8], [10]-[15], [17], [18], [20], [22], [24]-[27] | Urbanos, suburbanos, rurales, autopistas, áreas con peatones, y ciclistas | Tráfico mixto, variaciones climáticas y de iluminación, obstáculos estáticos y dinámicos, peatones |

IV. DISCUSIÓN

En este estudio de revisión, se ha identificado que el deep learning se aplica en varios aspectos críticos de los vehículos autónomos, como la percepción del entorno, detección de objetos, planificación de rutas, entre otros. Sin embargo, su uso conlleva riesgos, como la inexactitud en la percepción, errores de detección, falta de interpretabilidad, y vulnerabilidad a ataques. Para la identificación de los riesgos se utilizan técnicas de detección que incluyen validación cruzada, análisis de sensibilidad, fusión de sensores, entre otros. A su vez, se realizó pruebas en entornos simulados y de campo como carreteras, entornos urbanos, condiciones de tráfico, etc. y en condiciones variables como día, noche, niebla, nieve, etc. En comparación con un estudio con enfoque similar, se observó que el deep learning se utilizó principalmente para la percepción del entorno; las técnicas para mitigar los riesgos incluyeron la cuantificación de las incertidumbres, análisis de sensibilidad y validación cruzada; los principales riesgos identificados fueron inexactitudes en la percepción y vulnerabilidad a condiciones no previstas; y se llevó a cabo pruebas en entornos simulados en múltiples escenarios. [12]. Por otra parte, un estudio semejante, implementó un marco híbrido basado en deep learning para la detección y reconocimiento de objetos en la conducción autónoma; se empleó técnicas como la validación cruzada y pruebas en entornos simulados para evaluar y mitigar los riesgos asociados; los riesgos destacados incluyen errores de detección y falta de robustez ante diversas condiciones ambientales; y se probó el sistema tanto en simulaciones como en escenarios reales, tales como entornos urbanos y suburbanos. [13]. Asimismo, un estudio sobre la toma de decisiones en carreteras que usó deep learning, exploró la aplicación del

aprendizaje profundo en la toma de decisiones para vehículos autónomos en autopistas; se aplicó técnicas para la mitigación de riesgos como las pruebas en entornos simulados y el análisis de sensibilidad; se identificó riesgos como la inexactitud en las decisiones en tiempo real y la susceptibilidad a condiciones de tráfico no previstas; y se probó el sistema en escenarios simulados y reales, condiciones variadas como día, tarde, noche, y diferentes condiciones climáticas [16]. Además, otro estudio que sigue esta tendencia, se centró en la fusión de datos para el diagnóstico y tolerancia a fallos en sensores de vehículos autónomos; entre las técnicas para detectar y mitigar riesgos se incluyen el análisis de fallos y pruebas en entornos simulados; los riesgos identificados abarcan fallos de sensores y errores de interpretabilidad de los modelos; y se realizó pruebas en entornos simulados, y sobre diversas condiciones de tráfico y climáticas [20].

En lo que respecta al uso de deep learning en sistemas AV, se observa que, para la detección de peatones, los algoritmos YOLO y R-CNN se sugiere sean utilizados con conjuntos de datos como KITTI y Cityscapes. De manera similar, en tareas de reconocimiento de señales de tráfico, el algoritmo Faster R-CNN se recomienda con los mismos datasets. En comparación, un estudio sobre percepción del entorno, encontró que la aplicación de algoritmos como YOLO para la detección de peatones es útil para mejorar la seguridad urbana, especialmente en la identificación de transeúntes en diferentes condiciones ambientales [7]. Asimismo, en otro estudio con enfoque similar, se ha encontrado que los algoritmos como Faster R-CNN, entrenados con Cityscapes, se utilizan frecuentemente en la identificación de personas [26]. Por otro parte, la adopción sobre deep learning para el reconocimiento de señales de tráfico ha empleado algoritmos como CNN y conjuntos de datos extensivos como KITTI y Cityscapes para entrenar modelos que muestran mejoras en rendimiento [21]. Asimismo, otro estudio sobre la detección de señales de tráfico, revela que el uso de algoritmos como Faster R-CNN es común para alcanzar niveles de precisión adecuados, al aprovechar los mismos conjuntos de datos [22].

En relación a las técnicas para la detección de riesgos, se pudieron encontrar las pruebas en entornos simulados, análisis de vulnerabilidad, fusión de sensores, entre otros; en su mayoría utilizadas en la fase de entrenamiento de los modelos. En ese sentido, los algoritmos fueron evaluados en base a métricas o indicadores que pudieran corroborar que los riesgos sean mitigados respecto a la detección de objetos, lo que resultó en que el algoritmo CNN tuvo una precisión de detección de 92%, recall de 88%, f1-score de 89.7%, tasa de éxito en navegación 90%, tiempo de reacción de 200 ms, y un RMSE de 0.05, convirtiéndose en el algoritmo más preciso. En comparación, un estudio sobre la detección de objetos con sensores tuvo como resultado cierta similitud, con una precisión de detección del 90%, un recall de 85%, y un f1-score de 87.5% [3]. En esa línea, otro estudio sobre la detección de objetos demuestra que se logró una precisión del 91%, un recall del 87%, y un f1-score de 89% [4]. Del mismo modo, otro estudio referente a la detección de objetos indica que la precisión se mantuvo en un 88%, el recall en 83%, y el f1-score en 85% [18]. En contraste, un estudio sobre la detección de objetos enfocado en el uso del algoritmo YOLO revela que es el más exacto, con una precisión del 91%, un recall de 88%, y un f1-score de 89.8%, debido a su capacidad para procesar imágenes en tiempo real con un tiempo de reacción de 250 ms [15]. Esta diferencia se puede atribuir a las ventajas específicas de cada algoritmo, su adecuación a diferentes condiciones climáticas, y tipos de sensores utilizados.

Con respecto a los riesgos identificados a partir de la aplicación de deep learning en los sistemas de vehículos autónomos, se observa que los más frecuentes son los relacionados a la percepción del entorno, obstáculos imprevistos, interpretación errónea de objetos, y al uso del

sistema en condiciones climáticas adversas o con baja iluminación. En comparación, un estudio sobre percepción de objetos demuestra que puede verse afectada por la incapacidad de los sistemas de deep learning para adaptarse rápidamente a cambios súbitos en el entorno, como la aparición repentina de vehículos o peatones [11]. De la misma forma, otro estudio sobre la detección de objetos en carretera demuestra que muchas veces no se detectan obstáculos imprevistos, como animales o escombros, lo que puede resultar peligroso para el conductor y el entorno [14]. A su vez, un estudio que trata sobre la detección de objetos en horario nocturno revela cómo estos sistemas pueden realizar una interpretación errónea por la falta de iluminación, lo que compromete la seguridad [27]. Por otra parte, otro estudio sobre el uso de deep learning en condiciones climáticas adversas sugiere que factores como la lluvia intensa, la nieve o la niebla pueden degradar significativamente el rendimiento de los algoritmos, lo que dificulta la detección precisa de objetos y aumenta el riesgo de accidentes [2].

Acerca del contexto en que las pruebas fueron realizadas a los vehículos autónomos, se encontró que las evaluaciones fueron llevadas a cabo tanto en ambientes simulados como en pruebas de campo. La mayoría de los estudios combinaron ambas metodologías con el fin de obtener una evaluación más detallada de los sistemas. En relación a esto, un estudio sobre la detección en condiciones climáticas adversas optó por elegir las pruebas en entornos simulados porque permiten la recreación de escenarios climáticos extremos de manera controlada, lo que facilita la evaluación de los algoritmos en situaciones que serían difíciles de replicar en el campo [1]. Igualmente, otro estudio sobre la fusión de sensores multimodales siguió la misma tendencia y realizó pruebas en entornos simulados porque estos ambientes ofrecieron la posibilidad de ajustar y combinar diferentes datos sensoriales de manera precisa, lo que permitió evaluar la efectividad del modelo en múltiples condiciones sin las limitaciones del mundo real [5]. Por otro lado, un estudio sobre la detección de peatones optó por llevar a cabo pruebas en entornos simulados y de campo porque la combinación de ambos métodos proporcionó una visión completa del rendimiento del algoritmo, lo que verifica su eficacia tanto en condiciones controladas como en escenarios reales [6]. De igual forma, otro estudio de percepción se inclinó por esta misma opción debido a que permitió evaluar el algoritmo en entornos simulados, carreteras de zonas urbanas y rurales, condiciones climáticas variadas, etc, para medir el rendimiento del algoritmo, y como responde ante estos escenarios [17].

Por último, se realizan algunas sugerencias para futuras investigaciones, como por ejemplo investigar técnicas de validación cruzada y análisis de sensibilidad que puedan identificar riesgos con mayor precisión y adaptabilidad en condiciones reales; ampliar las pruebas en entornos con condiciones meteorológicas extremas y entornos no urbanos, para asegurar que los sistemas sean confiables en cualquier situación; y diseñar modelos de deep learning con mayor transparencia, que permitan a los ingenieros y usuarios finales entender el porque, y cómo se toman algunas decisiones por parte de los sistemas de vehículos autónomos.

V. CONCLUSIÓN

El objetivo de esta investigación fue identificar los riesgos asociados a la aplicación de deep learning en sistemas de vehículos autónomos. Tras un análisis exhaustivo, el resultado de la investigación fue que, si bien la implementación de deep learning tiene el potencial de mejorar significativamente la autonomía y seguridad de los vehículos, también se presentan riesgos importantes debido a su uso, como la susceptibilidad a presentar fallos en condiciones climáticas adversas, la detección errónea de objetos, la percepción deficiente del entorno, entre otros. En ese sentido, existen numerosos estudios que abordan la aplicación de deep learning en

estos sistemas, pero muy pocos se centran específicamente en los riesgos inherentes a su uso, lo que representa una limitación en la literatura actual. Es por ello que esta investigación contribuye como una base sólida para futuras exploraciones en este campo. Se recomienda que los futuros trabajos no solo profundicen en la identificación y mitigación de estos riesgos, sino que también se desarrollen marcos de regulación y estándares que garanticen la seguridad y confiabilidad de los vehículos autónomos impulsados por la aplicación de deep learning.

Esta investigación identificó que el deep learning es utilizado por los sistemas de vehículos autónomos principalmente en la percepción del entorno, detección de objetos, planificación de trayectorias, entre otros aspectos. Los algoritmos más recurrentes son CNN, RNN, YOLO, Faster R-CNN y GANs, y los datasets más utilizados incluyen KITTI, Cityscapes, ApolloScape, Waymo y COCO. Esto demuestra que el aprendizaje profundo es ampliamente aplicado en estos sistemas, con algoritmos y datos de entrenamiento específicos para diversas aplicaciones. En base a los resultados obtenidos, el deep learning se destaca por medio de los algoritmos de Redes Neuronales Convolucionales (CNN) y Redes Neuronales Recurrentes (RNN), junto a los datos de entrenamiento KITTI, por ser los más utilizados en aplicaciones críticas como la detección de objetos, la planificación de trayectorias y la navegación. Se recomienda que los futuros trabajos se enfoquen en investigar las razones por las cuales otros algoritmos no son tan considerados por los desarrolladores para su aplicación en los sistemas autónomos, y en explorar su potencial para mejorar la eficacia y seguridad de estos sistemas.

El presente estudio encontró que las técnicas de deep learning para la detección de riesgos en sistemas de vehículos autónomos más utilizadas son la validación cruzada, el análisis de sensibilidad, las pruebas en entornos simulados, la cuantificación de la incertidumbre y la fusión de sensores. A su vez, se evaluaron los algoritmos CNN, RNN, GANs, YOLO y Faster R-CNN, al aplicar previamente técnicas de mitigación de riesgos, con indicadores como precisión de detección, recall, F1-Score, tasa de éxito en la navegación, tiempo de reacción y error medio cuadrático (RMSE). La implementación de estas técnicas ha permitido demostrar que existe un margen de mejora en el rendimiento de un algoritmo al mitigar los riesgos identificados. En base a los resultados obtenidos, se destaca el algoritmo CNN por su precisión, siendo considerado el más eficiente para la detección de objetos. Se recomienda que los futuros trabajos se enfoquen en mejorar el rendimiento de los otros algoritmos de deep learning considerados en el estudio, para ampliar las opciones de elección.

Al aplicar deep learning en sistemas de vehículos autónomos se identificó algunos riesgos significativos, como la susceptibilidad a datos ruidosos o incompletos, la vulnerabilidad a ataques externos, y errores en la detección bajo condiciones climáticas adversas y de escasa visibilidad, entre otros. Para mitigar estos riesgos, se han propuesto soluciones como la mejora continua de los modelos mediante la incorporación de datos más variados y de alta calidad, el uso de técnicas de pre-procesamiento de imágenes, métodos de fusión de sensores, etc. Estos riesgos demuestran que los sistemas de vehículos no están exentos de presentar fallos en cualquier momento, y que la seguridad y la eficacia de estos sistemas dependen en gran medida de la precisión, fiabilidad y adaptabilidad de los algoritmos de deep learning empleados. Se observó que los riesgos más frecuentes están relacionados con la percepción del entorno, la interpretación errónea de objetos, y el uso del sistema en condiciones climáticas adversas. Entre las opciones de mitigación más comunes se encuentran el entrenamiento con datos diversos y el pre-procesamiento de datos. Se recomienda que los futuros trabajos se enfoquen en desarrollar y validar nuevas técnicas que aborden específicamente estos riesgos, lo que incluye la investigación en métodos avanzados de

fusión de sensores, técnicas de defensa contra ataques adversarios y el desarrollo de redes neuronales más adaptables a situaciones no entrenadas.

Por último, en esta investigación se encontró que las pruebas realizadas en los sistemas de vehículos autónomos incluyó tanto entornos simulados como pruebas de campo, una amplia variedad de escenarios (entornos urbanos, suburbanos, rurales y autopistas), y con condiciones climáticas diversas, variaciones en la iluminación, tráfico mixto, y la presencia de obstáculos estáticos y dinámicos. Estos estudios destacan la importancia de evaluar los sistemas en diversos contextos para obtener una visión más completa de su desempeño. Las evaluaciones de los sistemas de vehículos autónomos fueron realizadas en entornos simulados y de campo con el fin de obtener una evaluación más detallada y exhaustiva de los sistemas. Se recomienda que los futuros estudios continúen con la combinación de estas pruebas, y se sugiere ampliar los escenarios de prueba para incluir condiciones aún más variadas, como situaciones de emergencia y eventos imprevistos, con el fin de garantizar una mayor fiabilidad y adaptabilidad de los sistemas.

AGRADECIMIENTOS

Agradecemos a los autores de los artículos revisados por sus contribuciones, las cuales han sido fundamentales para el desarrollo de esta revisión de la literatura, así como a la universidad, y docentes por su apoyo constante.

REFERENCIAS

- [1] Q. A. Al-Haija, M. Gharaibeh, and A. Odeh, "Detection in Adverse Weather Conditions for Autonomous Vehicles via Deep Learning," *AI*, vol. 3, no. 2, pp. 303–317, Apr. 2022, doi: 10.3390/ai3020019.
- [2] Y. Almalioglu, M. Turan, N. Trigoni, and A. Markham, "Deep learning-based robust positioning for all-weather autonomous driving," *Nature Machine Intelligence*, vol. 4, no. 9, pp. 749–760, Sep. 2022, doi: 10.1038/s42256-022-00520-5.
- [3] J. D. Choi and M. Y. Kim, "A sensor fusion system with thermal infrared camera and LiDAR for autonomous vehicles and deep learning based object detection," *ICT Express*, vol. 9, no. 2, pp. 222–227, Apr. 2023, doi: 10.1016/j.ict.2021.12.016.
- [4] A. Hazarika, A. Vyas, M. Rahmati, and Y. Wang, "Multi-Camera 3D Object Detection for Autonomous Driving Using Deep Learning and Self-Attention Mechanism," *IEEE Access*, vol. 11, pp. 64608–64620, 2023, doi: 10.1109/ACCESS.2023.3288112.
- [5] Z. Huang, C. Lv, Y. Xing, and J. Wu, "Multi-Modal Sensor Fusion-Based Deep Neural Network for End-to-End Autonomous Driving With Scene Understanding," *IEEE Sensors Journal*, vol. 21, no. 10, pp. 11781–11790, May 2021, doi: 10.1109/JSEN.2020.3003121.
- [6] S. Iftikhar, Z. Zhang, M. Asim, A. Muthanna, A. Koucheryavy, and A. A. Abd El-Latif, "Deep Learning-Based Pedestrian Detection in Autonomous Vehicles: Substantial Issues and Challenges," *Electronics*, vol. 11, no. 21, p. 3551, Oct. 2022, doi: 10.3390/electronics11213551.
- [7] H.-H. Jebamikyous and R. Kashef, "Autonomous Vehicles Perception (AVP) Using Deep Learning: Modeling, Assessment, and Challenges," *IEEE Access*, vol. 10, pp. 10523–10535, 2022, doi: 10.1109/ACCESS.2022.3144407.
- [8] M. Khan, M. A. Raza, G. Abbas, S. Othmen, A. Yousef, and T. A. Jumani, "Pothole detection for autonomous vehicles using deep learning: a robust and efficient solution," *Frontiers in Built Environment*, vol. 9, Jan. 2024, doi: 10.3389/fbuil.2023.1323792.
- [9] D. Kim, A. Khalil, H. Nam, and J. Kwon, "OPEMI: Online Performance Evaluation Metrics Index for Deep Learning-Based Autonomous Vehicles," *IEEE Access*, vol. 11, pp. 16951–16963, 2023, doi: 10.1109/ACCESS.2023.3246104.
- [10] D.-H. Lee and J.-L. Liu, "End-to-end deep learning of lane detection and path prediction for real-time autonomous driving," *Signal, Image and Video Processing*, vol. 17, no. 1, pp. 199–205, Feb. 2023, doi: 10.1007/s11760-022-02222-2.

- [11] Y. Lee and S. Park, "A Deep Learning-Based Perception Algorithm Using 3D LiDAR for Autonomous Driving: Simultaneous Segmentation and Detection Network (SSADNet)," *Applied Sciences*, vol. 10, no. 13, p. 4486, Jun. 2020, doi: 10.3390/app10134486.
- [12] D. Li, B. Liu, Z. Huang, Q. Hao, D. Zhao, and B. Tian, "Safe Motion Planning for Autonomous Vehicles by Quantifying Uncertainties of Deep Learning-Enabled Environment Perception," *IEEE Transactions on Intelligent Vehicles*, vol. 9, no. 1, pp. 2318–2332, Jan. 2024, doi: 10.1109/TIV.2023.3297735.
- [13] Y. Li *et al.*, "A Deep Learning-Based Hybrid Framework for Object Detection and Recognition in Autonomous Driving," *IEEE Access*, vol. 8, pp. 194228–194239, 2020, doi: 10.1109/ACCESS.2020.3033289.
- [14] G. Li, H. Xie, W. Yan, Y. Chang, and X. Qu, "Detection of Road Objects With Small Appearance in Images for Autonomous Driving in Various Traffic Situations Using a Deep Learning Based Approach," *IEEE Access*, vol. 8, pp. 211164–211172, 2020, doi: 10.1109/ACCESS.2020.3036620.
- [15] S. Liang *et al.*, "Edge YOLO: Real-Time Intelligent Object Detection System Based on Edge-Cloud Cooperation in Autonomous Vehicles," *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 12, pp. 25345–25360, Dec. 2022, doi: 10.1109/TITS.2022.3158253.
- [16] J. Liao, T. Liu, X. Tang, X. Mu, B. Huang, and D. Cao, "Decision-Making Strategy on Highway for Autonomous Vehicles Using Deep Reinforcement Learning," *IEEE Access*, vol. 8, pp. 177804–177814, 2020, doi: 10.1109/ACCESS.2020.3022755.
- [17] A. Mauri, R. Khemmar, B. Decoux, T. Benmoumen, M. Haddad, and R. Boutheau, "A Comparative Study of Deep Learning-based Depth Estimation Approaches: Application to Smart Mobility," in *2021 8th International Conference on Smart Computing and Communications (ICSCC)*, IEEE, Jul. 2021, pp. 80–84. doi: 10.1109/ICSCC51209.2021.9528220.
- [18] I. Meftah, J. Hu, M. A. Asham, A. Meftah, L. Zhen, and R. Wu, "Visual Detection of Road Cracks for Autonomous Vehicles Based on Deep Learning," *Sensors*, vol. 24, no. 5, p. 1647, Mar. 2024, doi: 10.3390/s24051647.
- [19] K. Muhammad, A. Ullah, J. Lloret, J. del Ser, and V. H. C. de Albuquerque, "Deep Learning for Safe Autonomous Driving: Current Challenges and Future Directions," *IEEE Transactions on Intelligent Transportation Systems*, vol. 22, no. 7, pp. 4316–4336, Jul. 2021, doi: 10.1109/TITS.2020.3032227.
- [20] H. Pan, W. Sun, Q. Sun, and H. Gao, "Deep Learning Based Data Fusion for Sensor Fault Diagnosis and Tolerance in Autonomous Vehicles," *Chinese Journal of Mechanical Engineering*, vol. 34, no. 1, p. 72, Dec. 2021, doi: 10.1186/s10033-021-00568-1.
- [21] S. Paniego, E. Shinohara, and J. Cañas, "Autonomous driving in traffic with end-to-end vision-based deep learning," *Neurocomputing*, vol. 594, p. 127874, Aug. 2024, doi: 10.1016/j.neucom.2024.127874.
- [22] A. R. Rani, Y. Anusha, S. K. Cherishama, and S. V. Laxmi, "Traffic sign detection and recognition using deep learning-based approach with haze removal for autonomous vehicle navigation," *e-Prime - Advances in Electrical Engineering, Electronics and Energy*, vol. 7, p. 100442, Mar. 2024, doi: 10.1016/j.prime.2024.100442.
- [23] D. Schitz and H. Aschemann, "Path Optimization for Autonomous Driving using Deep Learning," *IFAC-PapersOnLine*, vol. 55, no. 27, pp. 490–496, 2022, doi: 10.1016/j.ifacol.2022.10.560.
- [24] Q. Sellat, S. Bisoy, R. Priyadarshini, A. Vidyarthi, S. Kautish, and R. K. Barik, "Intelligent Semantic Segmentation for Self-Driving Vehicles Using Deep Learning," *Computational Intelligence and Neuroscience*, vol. 2022, 2022, doi: 10.1155/2022/6390260.
- [25] T. Sharma *et al.*, "Deep Learning-Based Object Detection and Classification for Autonomous Vehicles in Different Weather Scenarios of Quebec, Canada," *IEEE Access*, vol. 12, pp. 13648–13662, 2024, doi: 10.1109/ACCESS.2024.3354076.
- [26] M. Sukkar, M. Shukla, D. Kumar, V. C. Gerogiannis, A. Kanavos, and B. Acharya, "Enhancing Pedestrian Tracking in Autonomous Vehicles by Using Advanced Deep Learning Techniques," *Information*, vol. 15, no. 2, p. 104, Feb. 2024, doi: 10.3390/info15020104.
- [27] H. Zhang, R. Sehab, S. Azouigui, and M. Boukhniifer, "Application and Comparison of Deep Learning Methods to Detect Night-Time Road Surface Conditions for Autonomous Vehicles," *Electronics*, vol. 11, no. 5, p. 786, Mar. 2022, doi: 10.3390/electronics11050786.