



Escuela Superior Politécnica del Litoral

Facultad de Ingeniería en Mecánica y Ciencias de la Producción

Revisión sistemática: El uso de inteligencia artificial para la detección de fatiga en conductores para la prevención de accidentes de tránsito

TRABAJO DE TITULACIÓN

Previo la obtención del Título de:

Magíster en Seguridad y Salud Ocupacional

Presentado por:

María Fiorella Abad Feraud

Evelyn Juliana Zarate Freire

Guayaquil - Ecuador

Año: 2026

Dedicatoria

Dedico este logro a Dios, por sostenerme en cada desafío. A mis padres y hermanos, por su amor y ejemplo constante. A mi hijo, mi mayor inspiración. Anhele que construya un camino aún más grande. A mis seres queridos, por su apoyo incondicional. Y a mí misma, por no rendirme y creer en mi capacidad de superación.

Evelyn Zarate Freire.

El presente proyecto lo dedico a todas las personas que, con su ejemplo, esfuerzo y constancia, han sido una fuente de inspiración en mi formación personal y académica.

A mi familia y de manera especial, a mi mamá y a mi papá, por su amor incondicional, por su apoyo permanente y por ser el pilar fundamental que sostiene cada uno de mis logros. Su ejemplo de dedicación y sacrificio ha sido la base sobre la cual he construido mis metas y sueños.

Fiorella Abad Feraud.

Agradecimientos

Expreso mi sincero agradecimiento a la ESPOL por los conocimientos brindados y por fortalecer mi formación profesional. A mis docentes y tutor, por su guía y acompañamiento constante en este proceso. A todas las personas que contribuyeron con su apoyo, comprensión y motivación, haciendo posible la culminación de este importante logro académico.

Evelyn Zarate Freire.

A Dios, por darme la fortaleza y la sabiduría para culminar este proceso.

A mi familia, por su apoyo incondicional; en especial a mis padres, a mi abuelita y a mis hermanos, por su amor, ejemplo y motivación constante para seguir creciendo.

A mis docentes, tutores y amigos de la maestría, por su acompañamiento y orientación durante este camino académico.

Fiorella Abad Feraud.

Declaración Expresa

Nosotros Abad Feraud María Fiorella y Zarate Freire Evelyn Juliana acordamos y reconocemos que:

La titularidad de los derechos patrimoniales de autor (derechos de autor) del proyecto de graduación corresponderá al autor o autores, sin perjuicio de lo cual la ESPOL recibe en este acto una licencia gratuita de plazo indefinido para el uso no comercial y comercial de la obra con facultad de sublicenciar, incluyendo la autorización para su divulgación, así como para la creación y uso de obras derivadas. En el caso de usos comerciales se respetará el porcentaje de participación en beneficios que corresponda a favor del autor o autores. La titularidad total y exclusiva sobre los derechos patrimoniales de patente de invención, modelo de utilidad, diseño industrial, secreto industrial, software o información no divulgada que corresponda o pueda corresponder respecto de cualquier investigación, desarrollo tecnológico o invención realizada por nosotros durante el desarrollo del proyecto de graduación, pertenecerán de forma total, exclusiva e indivisible a la ESPOL, sin perjuicio del porcentaje que nos corresponda de los beneficios económicos que la ESPOL reciba por la explotación de nuestra innovación, de ser el caso.

En los casos donde la Oficina de Transferencia de Resultados de Investigación (OTRI) de la ESPOL comunique a los autores que existe una innovación potencialmente patentable sobre los resultados del proyecto de graduación, no se realizará publicación o divulgación alguna, sin la autorización expresa y previa de la ESPOL.

Guayaquil, 14 de enero del 2026.

Abad Feraud María Fiorella

Zarate Freire Evelyn Juliana

Evaluadores

Kleber Barcia V., Ph.D.

Profesor de Materia

Cristhian Arias U., Ph.D.

Tutor de proyecto

Resumen

La fatiga al conducir incrementa el riesgo de accidentes viales por la disminución de las capacidades cognitivas y motoras del conductor. El objetivo fue analizar sistemáticamente el uso de la inteligencia artificial en la detección de fatiga en conductores, evaluando su efectividad, las tecnologías empleadas y su potencial contribución a la reducción de accidentes de tránsito. El estudio se justifica porque permite identificar las herramientas de inteligencia artificial más eficaces y formas de implementación. La metodología se basó en PRISMA, seleccionando 57 artículos que cumplieron los criterios de inclusión. Los resultados identificaron cinco categorías principales como sistemas basados en electroencefalograma con aprendizaje automático, visión computacional, soluciones multimodales, optimización para dispositivos embebidos y uso de señales fisiológicas complementarias. Las arquitecturas de aprendizaje profundo alcanzaron precisiones superiores al 90%, destacando redes convolucionales, LSTM y transformers. Los algoritmos clásicos, como Support Vector Machine lograron hasta 91,8% de exactitud, mientras que Random Forest y árboles de decisión superaron el 89%; sugiriendo que, combinar señales electroencefalográficas de pocos electrodos con enfoques multimodales y modelos explicables optimiza la detección temprana. Se concluye que la adopción masiva requiere sistemas no invasivos, modelos ligeros compatibles con Internet de las Cosas y validación continua en contextos de conducción natural.

Palabras Clave: Fatiga, somnolencia vehicular, IA, prevención de accidentes

Abstract

Fatigue while driving increases the risk of road accidents due to the decline in the driver's cognitive and motor skills. The objective was to systematically analyze the use of artificial intelligence in detecting fatigue in drivers, evaluating its effectiveness, the technologies used, and its potential contribution to reducing traffic accidents. The study is justified because it allows the identification of the most effective artificial intelligence tools and ways of implementation. The methodology was based on PRISMA, selecting 57 articles that met the inclusion criteria. The results identified five main categories as electroencephalogram-based systems with machine learning, computer vision, multimodal solutions, optimization for embedded devices, and the use of complementary physiological signals. Deep learning architectures achieved accuracies above 90%, with convolutional networks, LSTM, and transformers standing out. Classic algorithms, such as Support Vector Machine, achieved up to 91.8% accuracy, while Random Forest and decision trees exceeded 89%; suggesting that combining electroencephalographic signals from a few electrodes with multimodal approaches and explainable models optimizes early detection. It is concluded that mass adoption requires non-invasive systems, lightweight models compatible with the Internet of Things, and continuous validation in natural driving contexts.

Keywords: Fatigue, vehicular drowsiness, AI, accident prevention

Índice general

Evaluadores.....	v
Resumen.....	vi
Abstract.....	vii
Índice general.....	viii
Abreviaturas.....	x
Simbología.....	xi
Índice de figuras.....	xii
Índice de tablas.....	xiii
Capítulo 1.....	1
1. Introducción.....	2
1.1 Descripción del problema.....	3
1.2 Justificación del problema.....	4
1.3 Objetivos.....	5
1.3.1 Objetivo general.....	5
1.3.2 Objetivos específicos.....	5
1.4 Marco Teórico.....	5
1.4.1 Antecedentes.....	5
1.4.2 Inteligencia Artificial.....	6
1.4.3 Accidentes de tránsito.....	8
1.4.4 Inteligencia artificial y prevención de accidentes de tránsito.....	9

Capítulo 2.....	11
2. Metodología	12
2.1 Tipo de estudio	12
2.2 Diseño de investigación	12
2.3 Criterios de inclusión y exclusión	13
2.4 Estrategia de búsqueda	13
2.5 Procesamiento de la información	16
2.6 Estudios analizados	16
Capítulo 3.....	22
3. Resultados y análisis	23
3.1 Enfoques, modelos y algoritmos de inteligencia artificial utilizados para detectar fatiga o somnolencia en conductores.	23
3.2 Eficacia de estos sistemas de IA.	28
3.3 Recomendaciones que impulsen el uso de tecnologías de IA.	30
Capítulo 4.....	32
4. Conclusiones y recomendaciones	33
4.1 Conclusiones	33
4.2 Recomendaciones.....	35
Referencias	

Abreviaturas

ESPOL Escuela Superior Politécnica del Litoral

ADAS Sistemas Avanzados de Asistencia al Conductor

CNN Redes Neuronales Convolucionales

DL Aprendizaje Profundo

ECG Electrocardiograma

EEG Electroencefalograma

EOG Electrooculografía

HRV Variabilidad de la Frecuencia Cardíaca

IA Inteligencia Artificial

IoT Internet de las Cosas

KNN K-Vecinos más Cercanos

PRISMA Elementos de Reporte Preferidos para Revisiones Sistemáticas y Metaanálisis

SC Conductancia de la Piel

XAI Inteligencia Artificial Explicable

Simbología

α (alfa) Banda de frecuencia cerebral asociada con estado de relajación

β (beta) Banda de frecuencia cerebral asociada con estado de alerta

θ (theta) Banda de frecuencia cerebral asociada con somnolencia

δ (delta) Banda de frecuencia cerebral asociada con sueño profundo

p Valor de significancia estadística

% Porcentaje

Índice de figuras

Figura 1 Diagrama PRISMA	15
Figura 2 Enfoques de IA utilizados	23
Figura 3 Modelos de IA utilizados.....	25
Figura 4 Algoritmos de IA utilizados	27
Figura 5 Eficacia de sistemas de IA en prevención de accidentes.....	29
Figura 6 Recomendaciones para uso de IA en detección de fatiga de conductores	30

Índice de tablas

Tabla 1 Artículos incluidos en la revisión sistemática.....	16
---	----

Capítulo 1

1. Introducción

La fatiga en los conductores constituye uno de los principales riesgos para la seguridad vial a nivel mundial, particularmente en el sector del transporte pesado. Los datos muestran que alrededor del 20% de los accidentes de tránsito se encuentran directamente relacionados a la somnolencia, fatiga o a la disminución del estado de alerta del conductor (Gómez y Cuartas, 2020). En Estados Unidos, la fatiga es responsable de más de 100.000 siniestros de tránsito cada año, generando miles de lesiones y muertes que podrían evitarse mediante intervenciones preventivas oportunas (Pérez, 2025).

En América Latina, esta problemática se intensifica debido a condiciones laborales exigentes, jornadas prolongadas, deficiente control de los tiempos de descanso y una limitada implementación de tecnologías de monitoreo en los vehículos (Oviedo et al., 2025). En Ecuador, la Agencia Nacional de Tránsito (ANT) reconoce que la fatiga continúa siendo una causa subestimada y a la que no se le ha dado la atención debida, sin embargo, los registros disponibles evidencian que se trata de una causa recurrente en los accidentes de tránsito, (Agencia Nacional de Tránsito, 2021).

El desarrollo tecnológico reciente ha permitido la creación de sistemas basados en inteligencia artificial direccionados a la detección temprana de la fatiga en conductores. Estas soluciones integran sensores, cámaras, algoritmos de visión por computadora y modelos de aprendizaje profundo para identificar indicadores de somnolencia, como patrones de parpadeo, nivel del cierre ocular, movimientos de la cabeza, así como señales biométricas. A partir de este análisis, los sistemas generan alertas en tiempo real, constituyéndose en herramientas fundamentales para ayudar en la prevención de accidentes de tránsito (Magán et al., 2022).

A pesar del avance en este campo, la evidencia científica disponible es heterogénea, con estudios que analizan e implementan diferentes modelos de IA, así como distintos tipos

de metodologías y resultados que no son totalmente claros. Frente a esta, realidad, es necesario desarrollar una revisión sistemática de la literatura publicada entre los años 2020 al 2025 con el fin de valorar el impacto real de estas tecnologías y su aplicabilidad para mejorar la seguridad del conductor, prevenir accidentes y fortalecer los programas de salud y seguridad ocupacional en el sector del transporte pesado.

1.1 Descripción del problema

La fatiga en los conductores se presenta como consecuencia de aspectos relacionados con las largas jornadas de trabajo, esfuerzo visual y muscular, saturación mental, así como enfermedades físicas, constituyendo un riesgo tanto para su seguridad personal como para el bienestar de terceros (Noroña y Vega, 2022). Los choferes de vehículos se enfrentan a factores contextuales de diferente naturaleza que pueden afectar en su forma de manejar, siendo la fatiga uno de los más relevantes.

Como mencionan Duarte et al. (2023), la fatiga puede incrementar la posibilidad de cometer errores al momento de conducir debido a que se ven disminuidas las habilidades de la persona, como consecuencia de la sensación de somnolencia, esfuerzo físico, estrés u otro tipo de situaciones. Por esta razón, es importante establecer mecanismos de evaluación y prevención que ayuden a los conductores a tomar medidas para enfrentar los problemas asociados a las condiciones de cansancio que experimentan.

Con la evolución de la tecnología y de manera particular de la inteligencia artificial, se plantea el desarrollo de diferentes tipos de sistemas que pueden brindar alertas para prevenir situaciones de inseguridad vial provocadas por la fatiga. A propósito de esto Flores et al. (2023) menciona que es posible la implementación de herramientas de IA que pueden detectar el rostro del conductor, para introducirse a una red neuronal que analiza gestos o señales para identificar si el conductor presenta síntoma de somnolencia, fatiga con el fin de activar una alarma que los mantenga alertar y así evitar posibles accidentes.

A pesar del avance en este campo, la evidencia científica actual es heterogénea: existen estudios experimentales, simulados y de campo que utilizan diversos modelos de IA, con métodos distintos y resultados variables. Por ello, se requiere una revisión sistemática que sintetice la literatura científica publicada entre 2020 y 2025 para identificar los enfoques más efectivos, los algoritmos más precisos, los contextos de validación y las implicaciones para la seguridad vial de los conductores.

Por lo tanto, la pregunta que se plantea analizar en el presente estudio es: ¿De qué manera la inteligencia artificial aporta en la detección de fatiga en conductores, cuál es el nivel de efectividad, de las tecnologías empleadas y su contribución potencial a la reducción de accidentes de tránsito?

1.2 Justificación del problema

La investigación es importante a nivel académico, debido a que los estudios sobre el uso de la inteligencia artificial para detectar la fatiga en conductores son diversos y presentan diferentes tipos de enfoques. Por lo que es importante realizar una revisión sistemática que organice los diferentes puntos de vista de tal manera que sea posible analizar de una manera crítica esta temática e identificar claramente tanto los aportes como los aspectos aún no estudiados.

Metodológicamente, la investigación, se justifica porque será posible valorar la calidad de la metodología aplicada en los diferentes estudios, para verificar la validez de los aportes y de los resultados presentados. De esta manera será posible establecer criterios a tomar en cuenta al momento de realizar estudios acerca del uso de la inteligencia artificial para detección de fatiga en conductores y la prevención de accidentes de tránsito.

Además, a nivel social el estudio se justifica debido a que los accidentes de tránsito son una situación grave a nivel global, por lo que es considerado como un problema de salud pública. Por tanto, profundizar en el conocimiento del tema planteado puede aportar a definir

cuáles son las herramientas de inteligencia artificial más efectivas y cómo pueden ser implementadas en diferentes realidades a fin de contribuir a la mejora de la seguridad en las vías.

1.3 Objetivos

1.3.1 *Objetivo general*

Analizar sistemáticamente el uso de la inteligencia artificial en la detección de fatiga en conductores, identificando su efectividad, las tecnologías empleadas y su contribución potencial a la reducción de accidentes de tránsito.

1.3.2 *Objetivos específicos*

- Establecer los diferentes enfoques, modelos y algoritmos de inteligencia artificial utilizados detectando fatiga o somnolencia en conductores durante los últimos cinco años.
- Determinar la evidencia disponible sobre la eficacia de estos sistemas de IA en la prevención de incidentes o accidentes de tránsito, considerando estudios experimentales, simulados y en condiciones reales.
- Proponer recomendaciones que impulsen el uso de tecnologías de IA aplicadas a la detección de fatiga en conductores.

1.4 Marco Teórico

1.4.1 *Antecedentes*

La inteligencia artificial (IA) ha cobrado relevancia en los diferentes campos en los cuales se desarrolla la sociedad. Así, la prevención de accidentes de tránsito, es un campo en el que se ha implementado en los últimos tiempos, razón por la cual se han desarrollado diferentes estudios, algunos de los cuales se presentan a continuación.

Tal es el caso de la investigación titulada “Desarrollo de un sistema de alerta para la prevención de accidentes de tránsito mediante reconocimiento de señales y visión artificial” y elaborada por Jinez et al. (2025). En esta se plantea que los sistemas de visión artificial hacen posible capturar imágenes en tiempo real y analizarlas, por lo que se implementó un prototipo electrónico que opera mediante cámaras, alarmas, análisis de señales de tránsito en PYTHON y alcoholímetro, los cuales procesan todos los datos y emiten alertas automáticas a los conductores sobre potenciales peligros en las vías.

De igual manera, el estudio titulado “Uso de la Inteligencia Artificial (IA), aplicada al transporte público del cantón Santo Domingo, Provincia Santo Domingo de los Tsáchilas, año 2024” elaborado por Vaca y Sánchez (2025) muestra la utilidad de la IA en la conducción de vehículos, así como los desafíos que enfrenta. En el ámbito de la seguridad vial y la prevención de accidentes de tránsito, detallan cómo la herramienta de IA Waycare la cual analiza condiciones como el tráfico, analizando datos en tiempo real ayudando a disminuir las probabilidades de accidentes u otro tipo de riesgos.

Los dos estudios mencionados dan cuenta de la manera en que la IA puede ser aprovechada para reducir posibles riesgos al momento de conducir. Las diferentes maneras en que la IA puede ser implementada representan un aporte importante para incrementar la seguridad vial y brindar a los conductores opciones que pueden protegerlos de sufrir accidentes de tránsito que pueden poner en riesgo su vida o la de terceros.

1.4.2 Inteligencia Artificial

La inteligencia artificial es un campo de estudio que forma parte de la informática y se enfoca en el diseño de sistemas con la capacidad para imitar procesos cognitivos humanos, principalmente aquellos como el aprendizaje, el razonamiento, la percepción y la resolución de problemas. La IA tiene como finalidad la correcta interpretación de datos de tal manera que pueda aprender sobre diferentes ámbitos y posteriormente usarlos en el desarrollo de

diferentes tipos de acciones o tareas (Paredes et al., 2024). Además, de ayudar a automatizar y simplificar diferentes tipos de acciones, la IA es capaz de adaptarse y dar respuesta a diferente información, además de escenarios, por medio del aprendizaje automático, el procesamiento del lenguaje y la toma de decisiones autónomas.

Entre las principales características de los sistemas basados en IA se encuentran la capacidad de aprendizaje, la automatización de tareas complejas, el procesamiento y análisis de grandes volúmenes de datos y la toma de decisiones tomando en cuenta los patrones detectados. Además, los algoritmos de IA realizan funciones preprogramadas, y tienen la habilidad para la generalización de conocimientos que facilitan resolver diferentes problemáticas, así como optimizar procesos productivos y realizar ajustes de manera continua adaptándose a las transformaciones del entorno. Estos aspectos dan cuenta de las razones por las cuales la IA puede cumplir un rol importante en diferentes tipos de contextos como la educación, la medicina, la economía, la ingeniería, el transporte, entre otros (Castellón et al., 2024).

La IA es importante porque su funcionamiento ha logrado transformar las estructuras sociales, académicas, laborales, económicas y científicas en todo el mundo. En la actualidad, la IA está siendo integrada de manera progresiva a los campos educativos, sanitarios, industriales y laborales, contribuyendo en la mejora de los niveles de eficiencia, la precisión en los diagnósticos, la organización del trabajo, la personalización de servicios y su implementación en todas las áreas en las cuales la tecnología juega un papel esencial (Galvez, 2024). Por lo tanto, la implementación de las tecnologías de IA ayuda a impulsar el crecimiento económico y la innovación, sin embargo, es importante un uso ético y responsable de estos elementos para lograr mayores beneficios y reducir los posibles riesgos en sociedades cada vez más digitalizadas (Abieluk y Gutiérrez, 2021).

1.4.3 Accidentes de tránsito

Los accidentes de tránsito son imprevistos de carácter involuntario que se presentan en los espacios destinados a la circulación vehicular, intervienen uno a más autos, además de peatones, provocando daños materiales, lesiones o incluso la muerte de los involucrados. Se producen como consecuencia de la interacción de factores como las conductas o comportamientos de los conductores, fallas mecánicas, estado de las vías, señalización deficiente o condiciones climáticas. Son una de las principales causas de lesión y muerte a nivel mundial, por lo que la Organización Mundial de la Salud (OMS), lo considera como un problema de salud pública, que genera altos costos económicos y también sociales. A nivel de Latinoamérica, Ecuador es el segundo país con mayor número de accidentes de tránsito, con un nivel de 20,4 muertes por cada 100 mil habitantes (Oviedo et al., 2025).

En Ecuador, según datos del Instituto Ecuatoriano de Estadísticas y Censos, INEC (2025), durante el primer trimestre del 2025 se presentó un total de 4759 accidentes de tránsito, siendo los choques los de mayor incidencia con un 46,33%. Dentro de las principales causas se identificaron la imprudencia al conducir, el exceso de velocidad, no respeto a las señales de tránsito, embriaguez o drogas, rebasamiento imprudente, factores climáticos, imprudencia de los peatones, mal estado en las vías y daños mecánicos. Esto generó que existan un total de 4610 víctimas, de las cuales el 87,74% sufrieron lesiones y el 12,26% fallecieron.

Como mencionan Izurieta et al. (2024) los accidentes de tránsito son eventos de carácter previsible, debido a que su ocurrencia es la consecuencia de comportamientos de riesgo como el exceso de velocidad, conducir bajo los efectos del alcohol, distracción al volante, incumplimiento de normas de tránsito o la influencia de factores externos. Por lo tanto, es importante tomar medidas que ayuden a disminuir la posibilidad de que ocurran accidentes, mejorando la seguridad vial. Tal como explican Flores et al. (2023), en los

últimos tiempos la tecnología ha cobrado relevancia en este campo por la posibilidad de implementar sistemas que emitan alertas o muestren información para la prevención de siniestros de tránsito.

1.4.4 Inteligencia artificial y prevención de accidentes de tránsito

La inteligencia artificial, conforme ha ido alcanzando mayores niveles de desarrollo, ha sido incorporada para la creación de sistemas que ayuden a reducir la incidencia de accidentes de tránsito. Según expone Serrano et al. (2019) la integración de la IA en los sistemas de transporte es una estrategia importante para disminuir los riesgos asociados a la inseguridad vial, debido a que es posible crear sistema que ayuden a procesar información sobre la viabilidad en tiempo real, para la predicción de posibles escenarios que pudieran ser peligrosos en las vías como la congestión, vías en mal estado, accidentes, identificación de zonas de riesgos, favoreciendo a los conductores la toma de decisiones oportunas a fin de evitar riesgos.

Por su parte, Muñoz et al. (2024) que dentro de las tecnologías que la IA permite implementar en la prevención de accidentes de tránsito se encuentra el machine learning, que ayuda en el procesamiento de grandes volúmenes de datos para analizarlos, e identificar patrones de accidentes de tránsito que no son detectables fácilmente. Toma en cuenta variables como el tiempo, la geografía, condiciones climáticas, entre otras, considerando que los accidentes de tránsito son la consecuencia de una multiplicidad de factores que crean escenarios de riesgo.

Además, Magán et al. (2022) mencionan que los sistemas de IA, también poder ser utilizados para detectar estados de somnolencia o fatiga en los conductores, por medio del análisis automatizado de gestos y de comportamientos captados en tiempo real, mientras se maneja. Este tipo de sistemas utiliza machine learning y deep learning, basados en el uso de redes neuronales que procesan información obtenida a través de cámaras y sensores

instalados en el vehículo. Miden variables, como la frecuencia y duración del parpadeo, el porcentaje de cierre ocular, la dirección de la mirada, los movimientos de la cabeza y otro tipo de faciales. El procesamiento de estas características permite a la IA identificar patrones asociados a estados de fatiga o de disminución del nivel de alerta, incluso antes de que el conductor sea consciente, emitiendo sonidos, vibraciones u otro tipo de mecanismos para informar sobre esta situación y se tomen las medidas necesarias.

Capítulo 2

2. Metodología

La presente investigación se desarrolló bajo un enfoque de revisión sistemática, con base en los lineamientos PRISMA 2020. Para esto se realizó una búsqueda en diferentes bases de datos académicas, estableciendo un periodo de tiempo entre los años 2020 y 2025. A continuación, se explica con mayor detalle el proceso metodológico seguido para dar cumplimiento a los objetivos planteados.

2.1 Tipo de estudio

El estudio es de tipo descriptivo y explicativo. La investigación descriptiva se enfoca en conocer las principales características del objeto de investigación, a fin de comprender en profundidad el comportamiento de las variables en análisis (Ochoa y Yunkor, 2021). Mientras que la investigación explicativa hace posible indagar, interpretar y explicar las razones o causas alrededor de la problemática.

En el presente estudio, la investigación descriptiva hizo posible identificar y caracterizar la manera en que se utiliza la inteligencia artificial, como una herramienta con la capacidad para detectar la fatiga en los conductores, así como el tipo de tecnologías implementadas. Mientras que el estudio explicativo facilitó comprender la efectividad de estos sistemas de IA en la prevención de accidentes de tránsito, analizando las relaciones causales entre la implementación de estas tecnologías y reducción de incidentes viales, a partir de la evidencia recopilada.

2.2 Diseño de investigación

La investigación siguió un diseño no experimental de tipo revisión sistemática. Como explican Guevara et al. (2020) los estudios no experimentales, analizan la problemática tal como sucede en la realidad sin intervenir en el comportamiento de las variables. Por su parte, las revisiones sistemáticas, según expone Codina (2020) hacen posible conocer el aporte que

diferentes autores han realizado respecto a un tema determinado, en un lapso de tiempo específico, para establecer la forma en que los conocimientos han ido evolucionando, considerando diferentes puntos de vista.

2.3 Criterios de inclusión y exclusión

Los criterios de inclusión y exclusión aplicados para la búsqueda de los artículos incluidos en la revisión sistemática fueron los siguientes:

Criterios de inclusión

- Artículos científicos originales, revisiones sistemáticas o revisiones narrativas publicados en bases de datos y revistas académicas.
- Estudios que analicen el uso de inteligencia artificial aplicada a la detección de fatiga o somnolencia en conductores.
- Publicaciones en inglés y español.
- Estudios publicados entre los años 2020 al 2025
- Estudios con acceso a texto completo.

Criterios de exclusión

- Literatura gris, opiniones, editoriales o artículos no académicos.
- Estudios que no analicen el uso de inteligencia artificial aplicada a la detección de fatiga o somnolencia en conductores.
- Publicaciones en idiomas diferentes al inglés y español.
- Estudios publicados antes del año 2020.
- Estudios sin acceso a texto completo.

2.4 Estrategia de búsqueda

La búsqueda se realizó aplicando la metodología PRISMA para revisiones sistemáticas, la cual define los criterios a tomar en cuenta al momento de realizar la búsqueda

de la literatura científica a analizar (Page et al., 2021). La búsqueda inició con la identificación de bases de datos académicas en las cuales se identificarían los estudios, en este caso, fueron Scopus, PubMed, IEEE Xplore, ScienceDirect, SciELO y LILACS. En cada una se aplicaron los siguientes términos clave, tanto en inglés como en español:

Términos clave en inglés:

- Artificial intelligence
- Machine learning
- Deep learning
- Computer vision
- Driver fatigue
- Driver drowsiness
- Fatigue detection
- Driver monitoring systems
- Road safety
- Traffic accidents
- Accident prevention

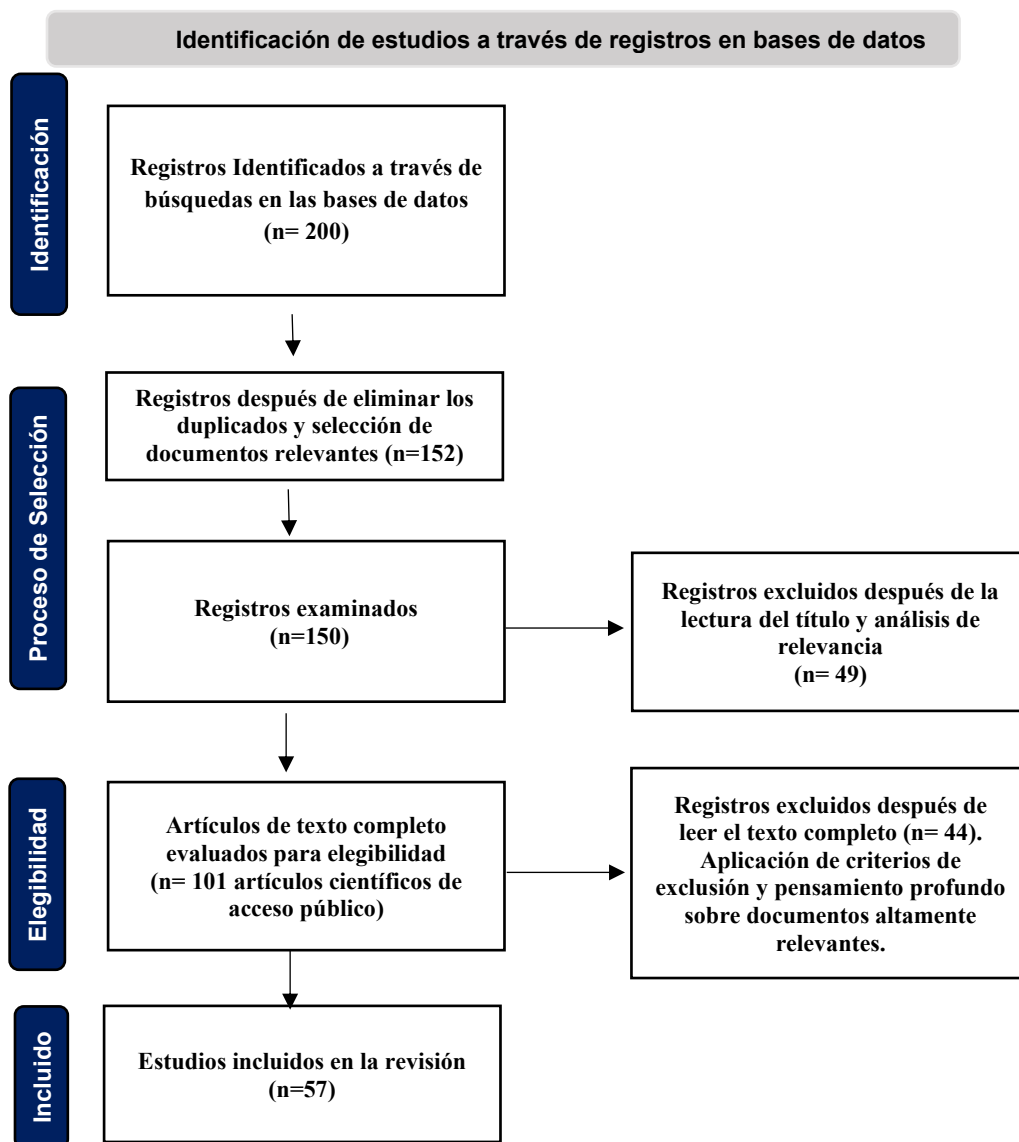
Términos clave en español:

- Inteligencia artificial
- Fatiga del conductor
- Somnolencia del conductor
- Detección de fatiga
- Sistemas de monitoreo del conductor
- Seguridad vial
- Accidentes de tránsito

Además, se establecieron como filtros de búsqueda los años entre el 2020 al 2025, el acceso a todo el artículo y el idioma. Una vez identificados los artículos, se procedió a eliminar aquellos duplicados y que no cumplieron con los criterios de inclusión y exclusión mencionados anteriormente. A continuación, se presenta la Figura 1, la cual muestra el diagrama PRISMA que describe el proceso de identificación, selección, elegibilidad e inclusión de los estudios considerados en la revisión sistemática.

Figura 1

Diagrama PRISMA



Nota. Elaboración propia con base en la búsqueda bibliográfica en las diferentes bases de datos.

2.5 Procesamiento de la información

La información de los artículos fue ingresada en una base de datos en la cual se colocaron los siguientes datos: título, año de publicación, autores, resumen, principales resultados. Posteriormente se realizó la lectura de los artículos extrayendo los datos más pertinentes para establecer los diferentes enfoques, modelos y algoritmos de inteligencia artificial utilizados para detectar fatiga o somnolencia en conductores durante los últimos cinco años; determinar la eficacia de estos sistemas; y, finalmente, plantear recomendaciones que impulsen el uso de IA para detectar la fatiga en conductores.

2.6 Estudios analizados

A continuación, se presenta el listado de los estudios analizados en la revisión sistemática (ver tabla 1):

Tabla 1

Artículos incluidos en la revisión sistemática

N	Título del artículo	Autores	Año
1	An Explainable Artificial Intelligence (XAI) Based Driver Fatigue Detection System For Safe And Care Human Life (SCHL)	P.Joy Kiruba, Dr.A.Sathya Sofia	2025
2	Optimized driver fatigue detection method using multimodal neural networks	Shengli Cao, Peihua Feng, Wei Kang, Zeyi Chen, & Bo Wang	2025
3	Designing an Embedded Feature Selection Algorithm for a Drowsiness Detector Model Based on Electroencephalogram Data	Bencsik B, Reményi I, Szemenyei M, Botzheim J. (Bencsik B, et al.)	2023
4	A Real-Time Embedded System for Driver Drowsiness Detection Based on Visual Analysis of the Eyes and Mouth Using Convolutional Neural Network and Mouth Aspect Ratio	Florez R, Palomino-Quispe F, Alvarez AB, Coaquira-Castillo RJ, Herrera-Levano JC. (Florez R, et al.)	2024
5	Highway Safety with an Intelligent Headlight System for Improved Nighttime Driving	Nkrumah JK, Cai Y, Jafaripournimchahi A, Wang H, Atindana VA. (Nkrumah JK, et al.)	2024

6	EEG Signal Multichannel Frequency-Domain Ratio Indices for Drowsiness Detection Based on Multicriteria Optimization	Stancin I, Frid N, Cifrek M, Jovic A. (Stancin I, et al.)	2021
7	Application of Graph Neural Network in Driving Fatigue Detection Based on EEG Signals	Mu Z, Jin L, Yin J, Wang Q. (Mu Z, et al.)	2022
8	Annotated drowsiness detection dataset captured using Raspberry Pi 5	Liawatimena S, Isworo N. (Liawatimena S, et al.)	2025
9	Drowsiness Detection Based on Intelligent Systems with Nonlinear Features for Optimal Placement of Encephalogram Electrodes on the Cerebral Area	Hong S, Baek HJ. (Hong S, et al.)	2021
10	Recent Advances in Portable Dry Electrode EEG: Architecture and Applications in Brain-Computer Interfaces	Zhang M, Qian B, Gao J, Zhao S, Cui Y, Luo Z, Shi K, Yin E. (Zhang M, et al.)	2025
11	Deep-ATM DL-LSTM: A novel adaptive thresholding model with dual-layer LSTM architecture for real-time driver drowsiness detection using skin conductance signals	Theivadas JR, Ponnan S. (Theivadas JR, et al.)	2025
12	Severity Analysis of Hazardous Material Road Transportation Crashes with a Bayesian Network Using Highway Safety Information System Data	Sun M, Zhou R, Jiao C, Sun X. (Sun M, et al.)	2022
13	Non-Invasive Driver Drowsiness Detection System	Siddiqui HUR, Saleem AA, Brown R, Bademci B, Lee E, Rustam F, Dudley S. (Siddiqui HUR, et al.)	2021
14	Driver drowsiness detection methods using EEG signals: a systematic review	Hussein RM, Miften FS, George LE. (Hussein RM, et al.)	2023
15	Electroencephalogram-Based Approaches for Driver Drowsiness Detection and Management: A Review	Li G, Chung WY. (Li G, et al.)	2022
16	Driver Drowsiness Detection: A Machine Learning Approach on Skin Conductance	Amidei A, Spinsante S, Iadarola G, Benatti S, Tramarin F, Pavan P, Rovati L. (Amidei A, et al.)	2023
17	A Review of Recent Developments in Driver Drowsiness Detection Systems	Albadawi Y, Takruri M, Awad M. (Albadawi Y, et al.)	2022

18	Driver Fatigue Detection Systems Using Multi-Sensors, Smartphone, and Cloud-Based Computing Platforms: A Comparative Analysis	Abbas Q, Alsheddy A. (Abbas Q, et al.)	2020
19	A systematic review of physiological signals based driver drowsiness detection systems	Saleem AA, Siddiqui HUR, Raza MA, Rustam F, Dudley S, Ashraf I. (Saleem AA, et al.)	2023
20	Physiological signal-based drowsiness detection using machine learning: Singular and hybrid signal approaches	Hasan MM, Watling CN, Larue GS. (Hasan MM, et al.)	2022
21	Real-Time Machine Learning-Based Driver Drowsiness Detection Using Visual Features	Albadawi Y, AlRedhaei A, Takruri M. (Albadawi Y, et al.)	2023
22	System and Method for Driver Drowsiness Detection Using Behavioral and Sensor-Based Physiological Measures	Bajaj JS, Kumar N, Kaushal RK, Gururaj HL, Flammini F, Natarajan R. (Bajaj JS, et al.)	2023
23	An Electro-Oculogram (EOG) Sensor's Ability to Detect Driver Hypovigilance Using Machine Learning	Murugan S, Sivakumar PK, Kavitha C, Harichandran A, Lai WC. (Murugan S, et al.)	2023
24	Driver drowsiness is associated with altered facial thermal patterns: Machine learning insights from a thermal imaging approach	Aghamalizadeh A, Mazloumi A, Nikabadi A, Nahvi A, Khaneshenas F, Ebrahimian S. (Aghamalizadeh A, et al.)	2024
25	InstanceEasyTL: An Improved Transfer-Learning Method for EEG-Based Cross-Subject Fatigue Detection	Zeng H, Zhang J, Zakaria W, Babiloni F, Gianluca B, Li X, Kong W. (Zeng H, et al.)	2020
26	Ultra-Wide Band Radar Empowered Driver Drowsiness Detection with Convolutional Spatial Feature Engineering and Artificial Intelligence	Siddiqui HUR, Akmal A, Iqbal M, Saleem AA, Raza MA, Zafar K, Zaib A, Dudley S, Arambarri J, Castilla ÁK, Rustam F. (Siddiqui HUR, et al.)	2024
27	Interpretable machine learning for evaluating risk factors of freeway crash severity	Samerei SA, Aghabayk K. (Samerei SA, et al.)	2024
28	A hybrid approach for driver drowsiness detection utilizing practical data to improve performance system and applicability	Khaneshenas F, Mazloumi A, Nahvi A, Nickabadi A, Sadeghniaat K, Rahimiforoushani A,	2024

		Aghamalizadeh A. (Khanehshenas F, et al.)	
29	Exploiting heart rate variability for driver drowsiness detection using wearable sensors and machine learning	AlArnaout Z, Zaki C, Kotb Y, AlAkkoumi M, Mostafa N. (AlArnaout Z, et al.)	2025
30	Efficient Generalized Electroencephalography-Based Drowsiness Detection Approach with Minimal Electrodes	Zayed A, Belhadj N, Ben Khalifa K, Bedoui MH, Valderrama C. (Zayed A, et al.)	2024
31	EEG quantization and entropy of multi-step transition probabilities for driver drowsiness detection via LSTM	Rayani MS, Ghimatgar H, Mansorinejad M. (Rayani MS, et al.)	2025
32	EffRes-DrowsyNet: A Novel Hybrid Deep Learning Model Combining EfficientNetB0 and ResNet50 for Driver Drowsiness Detection	Al-Gburi SH, Al-Sammak KA, Marghescu I, Oprea CC, Drăgulinescu AC, Alduais NAM, Alheeti KMA, Al-Sammak NAH. (Al-Gburi SH, et al.)	2025
33	A Review of EEG Signal Features and their Application in Driver Drowsiness Detection Systems	Stancin I, Cifrek M, Jovic A. (Stancin I, et al.)	2021
34	Deep Learning for Detecting Multi-Level Driver Fatigue Using Physiological Signals: A Comprehensive Approach	Peivandi M, Ardabili SZ, Sheykhivand S, Danishvar S. (Peivandi M, et al.)	2023
35	Drowsiness Detection Using Ocular Indices from EEG Signal	Tarafder S, Badruddin N, Yahya N, Nasution AH. (Tarafder S, et al.)	2022
36	Real-Time Fatigue Detection Algorithms Using Machine Learning for Yawning and Eye State	Makhmudov F, Turimov D, Xamidov M, Nazarov F, Cho YI. (Makhmudov F, et al.)	2024
37	Validation and interpretation of a multimodal drowsiness detection system using explainable machine learning	Hasan MM, Watling CN, Larue GS. (Hasan MM, et al.)	2024
38	Current status and challenges in electroencephalography (EEG)-based driver fatigue detection: a comprehensive survey	Hassan J, Naziullah S, Rashid M, Islam T, Islam MN, Islam MS, Mahmud S. (Hassan J, et al.)	2025
39	A compact and interpretable convolutional neural network for cross-subject driver drowsiness detection from single-channel EEG	Cui J, Lan Z, Liu Y, Li R, Li F, Sourina O, Müller-Wittig W. (Cui J, et al.)	2022

40	DDD TinyML: A TinyML-Based Driver Drowsiness Detection Model Using Deep Learning	Alajlan NN, Ibrahim DM. (Alajlan NN, et al.)	2023
41	Driving drowsiness detection using spectral signatures of EEG-based neurophysiology	Arif S, Munawar S, Ali H. (Arif S, et al.)	2023
42	Real-Time Driver Drowsiness Detection Using Facial Analysis and Machine Learning Techniques	Essahraoui S, Lamaakal I, El Hamly I, Maleh Y, Ouahbi I, El Makkaoui K, Filali Bouami M, Pławiak P, Alfarraj O, Abd El-Latif AA. (Essahraoui S, et al.)	2025
43	FastKAN-DDD: A novel fast Kolmogorov-Arnold network-based approach for driver drowsiness detection optimized for TinyML deployment	Essahraoui S, Lamaakal I, Maleh Y, El Makkaoui K, Bouami MF, Ouahbi I, Elmannai H, Abd El-Latif AA. (Essahraoui S, et al.)	2025
44	Multi-body sensor based drowsiness detection using convolutional programmed transfer VGG-16 neural network with automatic driving mode conversion	Malik M, Sharma P, Punj GK, Singh S, Gared F. (Malik M, et al.)	2025
45	Smart IoT-driven biosensors for EEG-based driving fatigue detection: A CNN-XGBoost model enhancing healthcare quality	Rezaee K, Nazerian A, Ghayoumi Zadeh H, Attar H, Khosravi M, Kanan M. (Rezaee K, et al.)	2024
46	Lightweight and Real-Time Driver Fatigue Detection Based on MG-YOLOv8 with Facial Multi-Feature Fusion	Chengming Chen, Xinyue Liu, Meng Yu, Chenfeng Wang, Hu Chen, Tongwei Li	2025
47	Real-Time Fatigue Detection Algorithms Using Machine Learning for Yawning and Eye State	Young-Im Cho, et al.	2024
48	Fatigue monitoring using wearables and AI: Trends, challenges, and future opportunities	K. Kakhi, S.K. Jagatheesaperumal, A. Nasr, et al.	2025
49	Preventive Detection of Driver Drowsiness from EEG Signals using Fuzzy Expert Systems	Rony Almirón, Roberto A. Castillo, Andrés A. Montoya et al.	2024
50	Early Driver Fatigue Detection System: A Cost-Effective and Wearable Approach Utilizing Embedded Machine Learning	Chengyou Lin, Xinying Zhu, Renpeng Wang, Wei Zhou, Na Li, Yu Xie	2025

51	Optimized driver fatigue detection method using multimodal neural networks nature.com	Shengli Cao, Linyan Feng, Wei Kang, Weihua Huang	2025
52	Real-time driver drowsiness detection using transformer architectures: a novel deep learning approach nature.com	Osama F. Hassan, Ahmed F. Ibrahim, Ahmed Gomaa, Reem A. Hussein, Mohamed A. Mohamed	2025
53	A CNN-Based Approach for Driver Drowsiness Detection by Real-Time Eye State Identification mdpi.com	Ruben D. Florez Zela, Facundo Palomino-Quispe, Roger J. Coaquira-Castillo, Julio C. Herrera-Levano, Thuanne Paixão, Ana B. Álvarez	2023
54	Driver Fatigue Detection Using Heart Rate Variability Features from 2-Minute ECG Signals While Accounting for Sex Differences mdpi.com	Chao Zeng, Jiliang Zhang, Yizi Su, Shuguang Li, Zhenyuan Wang, Qingkun Li, Wenjun Wang	2024
55	Deep Learning for Detecting Multi-Level Driver Fatigue Using Physiological Signals: A Comprehensive Approach mdpi.com	Mohammad Peivandi, Sevda Z. Ardabili, Sobhan Sheykhivand, Sebelan Danishvar	2023
56	YOLO-FDCL: Improved YOLOv8 for Driver Fatigue Detection in Complex Lighting Conditions mdpi.com	Genchao Liu, Kun Wu, Wei Lan, Yunjie Wu	2025
57	A Novel Approach for Automatic Detection of Driver Fatigue Using EEG Signals Based on Graph Convolutional Networks mdpi.com	Sevda Z. Ardabili, Soufia Bahmani, Lida Z. Lahijan, Nastaran Khaleghi, Sobhan Sheykhivand, Sebelan Danishvar	2024

Nota. Elaboración propia, con base en la búsqueda en las diferentes bases de datos.

En total, como parte de la revisión sistemática, se plantea el análisis de 57 artículos, los cuales cumplen con los criterios de inclusión establecidos para el desarrollo del presente estudio.

Capítulo 3

3. Resultados y análisis


La presente revisión sistemática analizó 57 artículos científicos publicados entre 2020 y 2025. El 67% de los estudios (n=38) fueron publicados en los últimos tres años (2023-2025), evidenciando un crecimiento exponencial del interés científico en esta área. La mayoría de las investigaciones provinieron de revistas indexadas en Scopus y Web of Science, siendo *Sensors* (MDPI) la fuente más recurrente con 24 publicaciones (41,4%).

3.1 Enfoques, modelos y algoritmos de inteligencia artificial utilizados para detectar fatiga o somnolencia en conductores.

En cuanto a la revisión realizada sobre los enfoques de inteligencia artificial aplicados para la detección de fatiga o somnolencia en conductores, se tienen los siguientes resultados:

Figura 2

Enfoques de IA utilizados



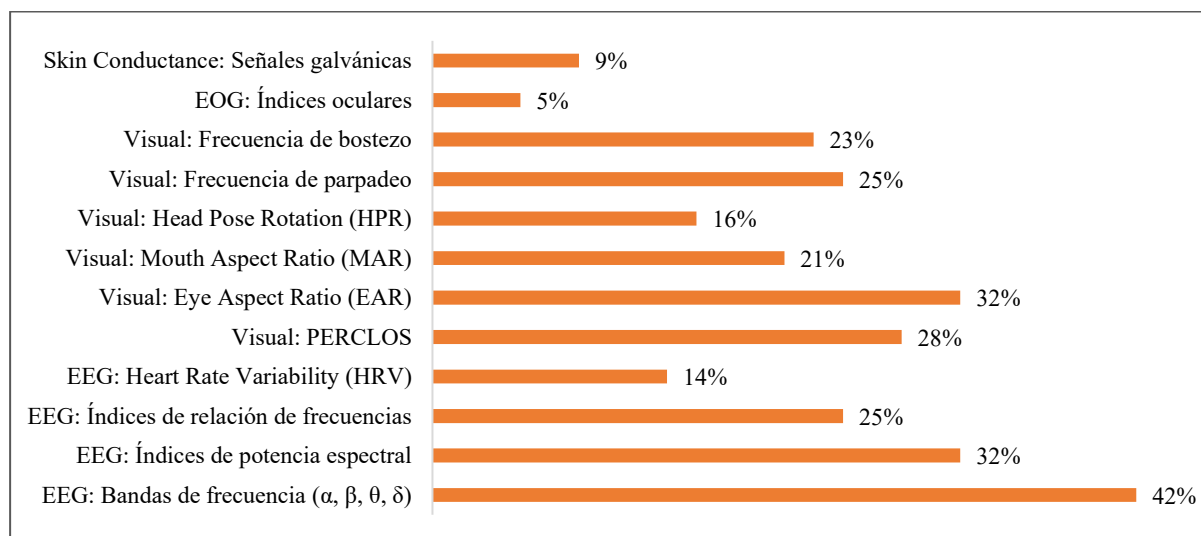
Nota. La figura muestra los enfoques identificados de IA utilizados para la detección de fatiga o somnolencia en conductores.

En la Figura 2, se aprecia que del total de 57 artículos se identificó y clasificó los enfoques de IA empleados, esto se agruparon en cinco categorías principales. La mayoría (18) corresponde al 32% de EEG (electroencefalograma) + ML (Machine Learning) /DL (Deep Learning), pues, proporcionan acceso directo a la actividad cerebral y facilitan la detección del estado de fatiga previo a la manifestación conductual (Tarafer et al., 2022; Hassan et al., 2025;

Cui et al., 2022; Arif et al., 2023; Rezaee et al., 2025; Almirón et al., 2024; Zeng C. et al., 2024; Ardabili et al., 2024), por ende, la combinación de arquitecturas profundas con algoritmos de ensamble optimiza los resultados (Bencsik et al., 2023; Stancin et al., 2021; Hong y Baek, 2021; Hussein, 2023; Li y Chung, 2022; Zeng H. et al., 2020; Zayed et al., 2024; Rayani et al., 2025; Stancin et al., 2021).

Seguidamente se ubican 12 artículos sobre visión por computadora (21%), donde los sistemas visuales no necesitan contacto físico con los conductores, lo cual se puede implementar masivamente en vehículos particulares. Después se encuentran 10 estudios sobre sistemas multimodales (17%), donde se integran los datos heterogéneos (EEG, ECG, imágenes faciales) mediante mecanismos de acoplamiento (Khanehshenas et al., 2024; Feng et al., 2025; Cho et al., 2024). Luego están 9 artículos (16%) sobre optimización para dispositivos embebidos (TinyML), arquitecturas IoT distribuidas y explicabilidad (XAI). Incluso la integración de deep learning con dispositivos IoT enfrentaba problemas por recursos computacionales mientras que, TinyML surge como respuesta, optimizando modelos para ejecutar en microcontroladores.

En el último enfoque están 8 artículos relacionados con señales fisiológicas como electrocardiograma (ECG), variabilidad de frecuencia cardíaca (HRV) y conductancia de la piel (SC). Por lo tanto, se evidencia una tendencia hacia modelos de deep learning, especialmente CNN, LSTM, Transformers y GCN con una evolución reciente hacia modelos explicables (XAI) y arquitecturas ligeras (TinyML).

Figura 3*Modelos de IA utilizados*

Nota. La figura muestra los modelos identificados de IA utilizados para la detección de fatiga o somnolencia en conductores.

La Figura 3 presenta los modelos de IA que se utilizan en la detección de fatiga de los conductores. Los resultados evidencian que las señales EEG son la modalidad más utilizada en IA para la detección de fatiga en conductores, destacando especialmente el análisis de bandas de frecuencia (α , β , θ y δ), presente en el 42% de los estudios de un total de 57 artículos analizados. Diversos autores señalan que estas bandas representan cambios neurofisiológicos asociados a la somnolencia y disminución de la atención, explicando la amplia adopción en modelos basados en aprendizaje automático y profundo (Hong y Baek, 2021; Hussein, 2023; Li y Chung, 2022; Hassan et al., 2025). Asimismo, otras investigaciones han demostrado que la combinación de bandas con arquitecturas avanzadas como CNN, LSTM o Graph Neural Networks mejora significativamente la precisión diagnóstica (Rayani et al., 2025; Cui et al., 2022; Ardabili et al., 2024).

En concordancia con lo anterior, los índices de potencia espectral y relación entre frecuencias EEG se utilizaron en el 32% y 25% de los artículos respectivamente, en el que se proporciona características cuantitativas robustas para los modelos de IA. En el trabajo de

Stancin et al. (2021) y Arif et al. (2023), demostraron que estos índices permiten discriminar de forma fiable entre estados de vigilia y somnolencia, reduciendo la complejidad computacional sin comprometer la precisión. Además, enfoques de transferencia de aprendizaje y optimización inter-sujeto han sido propuestos para superar la variabilidad individual del EEG, aumentando la generalización de los modelos (Zeng H. et al., 2020; Zayed et al., 2024).

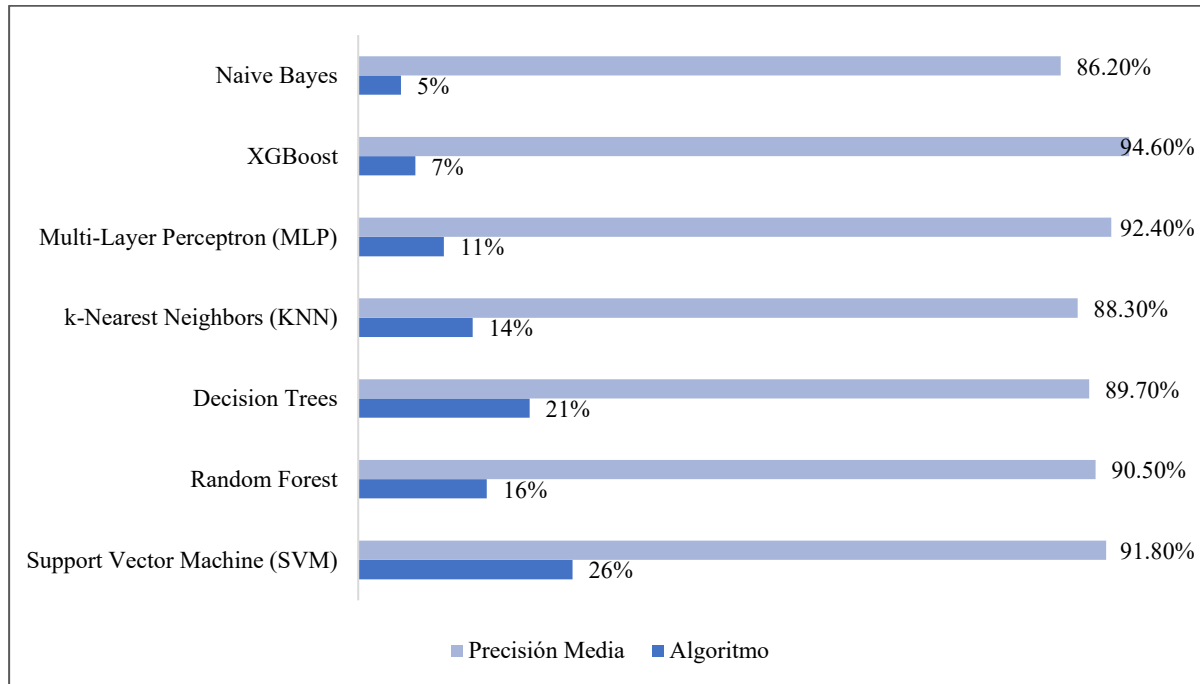
Por otra parte, la modalidad visual representa un enfoque no invasivo aceptado con énfasis en variables como Eye Aspect Ratio (EAR), PERCLOS y frecuencia de parpadeo, presentes en aproximadamente un tercio de los estudios. Estas características han demostrado ser efectivas para la detección de fatiga en tiempo real mediante visión por computadora (Albadawi et al., 2022; Makhmudov et al., 2024; Florez R. et al., 2023) y redes neuronales convolucionales (Florez et al., 2024; Albadawi et al., 2023; Essahraoui et al., 2025). En otros integran múltiples indicadores faciales, incluyendo MAR y rotación de la cabeza en modelos ligeros como YOLOv8 o arquitecturas híbridas, logrando alta precisión, incluso bajo condiciones de iluminación adversas (Chen et al., 2025; Liu et al., 2025).

Finalmente, las modalidades fisiológicas complementarias como la variabilidad de la frecuencia cardíaca (HRV), conductancia galvánica de la piel y EOG presentan menor frecuencia de uso, pero, aportan valor en enfoques multimodales. En este contexto, la Figura 4 muestra la integración de estas señales fisiológicas dentro de modelos híbridos de detección de fatiga, evidenciando cómo la combinación de variables autonómicas y neurofisiológicas fortalece la capacidad predictiva de los sistemas basados en inteligencia artificial. Es así, en estudios basados en HRV y señales de piel muestran que, la activación del sistema nervioso autónomo puede mejorar la detección temprana de fatiga cuando se combinan con EEG o visión artificial (AlArnaout et al., 2025; Zeng C. et al., 2024; Theivadas y Ponnann, 2025). Por lo tanto, existe una tendencia creciente hacia modelos multimodales y explicables, que integran múltiples fuentes de datos para aumentar la robustez, precisión y aplicabilidad de los sistemas de prevención de

accidentes de tránsito basados en IA (Cao et al., 2025; Feng et al., 2025; Hasan et al., 2024; Kiruba y Sofia, 2025).

Figura 4

Algoritmos de IA utilizados



Nota. La figura muestra los algoritmos identificados de IA utilizados para la detección de fatiga o somnolencia en conductores.

En cuanto a los algoritmos de IA, en la Figura 4 se observa que, un 26% de los artículos utilizaron Support Vector Machine (SVM) en la detección de fatiga en conductores y una precisión media del 91,8%. La adopción de este algoritmo se explica por la capacidad para manejar conjuntos de datos de alta dimensionalidad y buen desempeño con señales fisiológicas ruidosas, especialmente EEG; es decir, logra una clasificación robusta de los estados de alerta y somnolencia, incluso con un número reducido de electrodos para sistemas de detección en tiempo real (Stancin et al., 2021; Hong y Baek, 2021; Zayed et al., 2024; Saleem et al., 2024; Aghamalizadeh et al., 2024; Amidei et al., 2023; Murugan et al., 2023). Luego se ubican con 21% los árboles de decisión y 16% Random Forest con precisiones medias entre 89,7% y 90,5% respectivamente. Según Sun et al. (2022); Hasan et al. (2024); Zeng et al. (2024); Samerei y

Aghabayk (2024), consideran que, el algoritmo Random Forest mejora la robustez mediante la combinación de múltiples árboles, mientras que los modelos basados en árboles de decisión facilitan la identificación de variables fisiológicas y conductuales.


El algoritmo k-Nearest Neighbors (KNN), fue utilizado en el 14% de los estudios, alcanzando una precisión media del 88,3%, siendo, empleado como método comparativo por la simplicidad y facilidad de implementación en estudios exploratorios, como los presentados por Mu et al. (2022) y Hasan et al. (2024). Luego, con un 11% se encuentra el algoritmo Multi-Layer Perceptron (MLP) con una precisión del 92,4%, siendo, potencial de las redes neuronales para modelar relaciones no lineales complejas en señales EEG y fisiológicas (Saleem et al., 2024; Zayed et al., 2024). Los menos frecuentes son XGBoost (7%) y Naive Bayes (5%) con precisión entre 94,6% y 86,2% respectivamente; donde el primero tiene un alto poder predictivo y capacidad de optimización (AlArnaout et al., 2025; Rezaee et al., 2025), en cambio, el segundo se usa como línea base comparativa (Hasan et al., 2022; Saleem et al., 2024). Por lo tanto, se identificó que la mayoría utiliza algoritmos clásicos, pero existe una tendencia creciente hacia modelos más avanzados y optimizados; pues son capaces de mejorar tanto la precisión como viabilidad de los sistemas de detección de fatiga para la prevención de accidentes de tránsito.

3.2 Eficacia de estos sistemas de IA.

En este apartado se presentan los resultados obtenidos en la revisión sistemática sobre la eficacia de estos sistemas de IA en la prevención de incidentes o accidentes de tránsito, considerando estudios experimentales, simulados y en condiciones reales.

Figura 5

Eficacia de sistemas de IA en prevención de accidentes



Nota. La figura muestra la eficacia de los sistemas de IA en la prevención de accidentes o incidentes.

En la Figura 5 se observa que el 23% de los artículos corresponden a estudios experimentales desarrollados en laboratorio o simulador, reportando valores de accuracy entre 89% y 99,8% con significancia estadística ($p < 0,05$). Es así que, los estudios relacionados con señales EEG y fisiológicas exponen un alto desempeño en entornos controlados, permitiendo validar la capacidad discriminativa de los modelos antes de la implementación real (Cao et al., 2025; Stancin et al., 2021; Zeng H. et al., 2020; Rayani et al., 2025; Cui et al., 2022; Ardabili et al., 2024; Peivandi et al., 2023). Asimismo, se identifica un avance hacia la detección de fatiga en tiempo real, evidenciado en el 16% de los estudios, los cuales implementan sistemas en cabina vehicular o mediante dispositivos wearables, alcanzando precisiones superiores al 95% y baja latencia. En trabajos relacionados con la visión artificial, radar, sensores portátiles y arquitecturas ligeras de deep learning evidencian que es posible detectar la somnolencia de manera continua sin afectar la experiencia del conductor (Florez R. et al., 2024; Albadawi et al., Real-Time Machine Learning-Based Driver Drowsiness Detection Using Visual Features, 2023; AlArnaout et al., 2025; Liu et al., 2025; Siddiqui et al., 2021; Siddiqui et al., 2024; Alajlan y Ibrahim, 2023; Lin et al., 2025; Hassan et al., 2025).

Por otro lado, el 11% de los artículos se aprecia validación en condiciones reales, en el que se evalúan los modelos en contextos de conducción natural, tráfico real o sistemas ADAS;

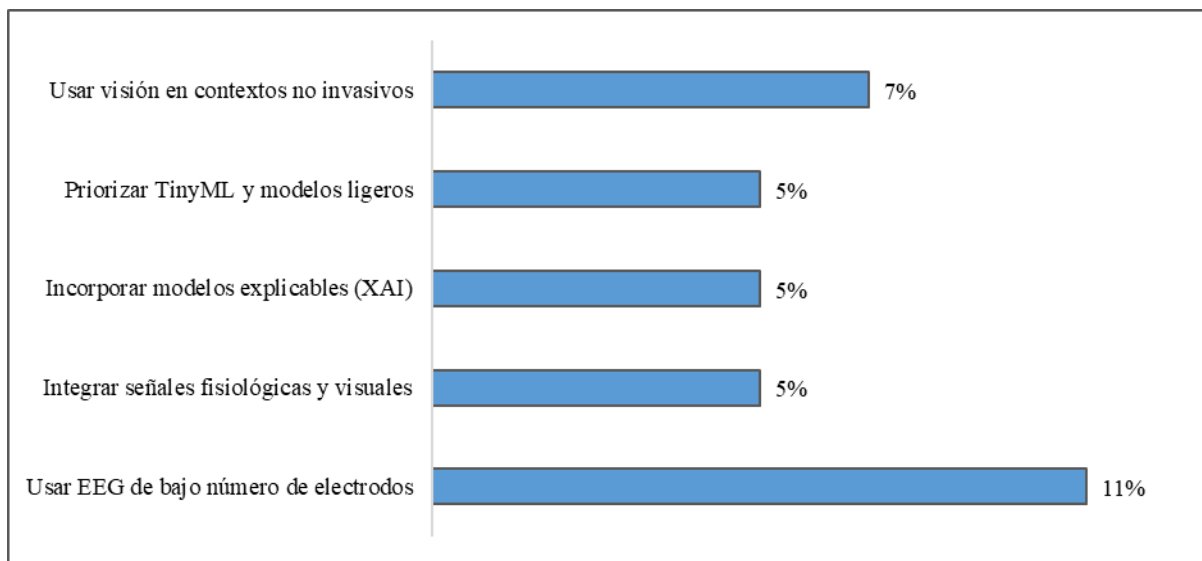
disminuyendo de errores y estabilidad del rendimiento. La integración de múltiples sensores mejora la confiabilidad del sistema y reduce falsos positivos, aspecto crítico para la adopción práctica (AlArnaout et al., 2025; Lin et al., 2025; Abbas y Alsheddy, 2021; Bajaj et al., 2023; Malik et al., 2025; Kakhi et al., 2025). En ese sentido, se identificó que casi la mitad de los estudios (49%) presenta pruebas claras de eficacia en entornos experimentales, tiempo real o condiciones reales de conducción; evidenciando evolución desde pruebas controladas hacia implementaciones aplicables en escenarios reales.

3.3 Recomendaciones que impulsen el uso de tecnologías de IA.

Los resultados sobre las recomendaciones que impulsen el uso de tecnologías de IA aplicadas a la detección de fatiga en conductores se detallan a continuación:

Figura 6

Recomendaciones para uso de IA en detección de fatiga de conductores



Nota. La figura muestra la eficacia de los sistemas de IA en la fatiga de los conductores.

En la Figura 6 se aprecia que, un 11% de los artículos recomienda el uso de EEG con un bajo número de electrodos, evidenciando que, es posible alcanzar alta precisión en la detección de fatiga. En la selección óptima de características y arquitecturas se deben considerar configuraciones con pocos canales para un adecuado rendimiento (Stancin et al., 2021; Zeng H. et al., 2020; Zayed et al., 2024; Rezaee et al., 2025; Ardabili et al., 2024; Bencsik et al., 2023).

Otra recomendación es la integración de enfoques multimodales; aunque solo el 5% de los artículos aborda esta estrategia, los resultados presentan mejoras frente a la variabilidad individual y ambiental. Los modelos que fusionan EEG, señales cardíacas, datos visuales y sensores portátiles logran una detección más confiable en escenarios reales (Hasan et al., 2024; Cao et al., 2025; Abbas y Alsheddy, 2021).

La necesidad de adopción de usuarios y entidades reguladoras justifica la recomendación de incorporar modelos explicables (XAI). En el que se destaca que la interpretabilidad de los modelos de IA permite comprender qué variables influyen en la detección de fatiga, facilitando la validación clínica y aceptación en sistemas de seguridad vial. Cuando se aplican árboles de decisión, redes neuronales interpretables y enfoques explicables, aumenta la confianza, mejora la capacidad de ajuste y mantenimiento del sistema (Hasan et al., 2024; Kiruba y Sofia, 2025; Cui et al., 2022). Las recomendaciones se orientan a la implementación práctica, pues, el éxito de la visión computarizada no invasiva y validación en condiciones reales de conducción. Por lo que, el uso de TinyML, arquitecturas eficientes y visión artificial permiten contar con sistemas de detección de fatiga con bajo consumo computacional y precisión en tiempo real (Alajlan y Ibrahim, 2023; Essahraoui et al., 2025; Lin et al., 2025; Florez R. et al., 2024; Albadawi et al., Real-Time Machine Learning-Based Driver Drowsiness Detection Using Visual Features, 2023; Liu et al., 2025; Al-Gburi et al., 2025). Asimismo, los estudios en carretera y con sensores reales refuerzan la recomendación de priorizar validaciones en entornos naturales para garantizar la efectividad y adopción (Siddiqui et al., 2021; Siddiqui et al., 2024; AlArnaout et al., 2025; Essahraoui et al., 2025). Con base en la evidencia recopilada, es importante priorizar el uso de EEG con un número reducido de electrodos, ya que permite mantener una alta precisión en la detección de fatiga, y menor intrusividad; integrando enfoques multimodales, modelos explicables, ligeros, eficientes, compatibles con entornos IoT y sistemas vehiculares.

Capítulo 4

4. Conclusiones y recomendaciones

4.1 Conclusiones

1. Se establecieron los diferentes enfoques, modelos y algoritmos de inteligencia artificial utilizados para detectar fatiga o somnolencia en conductores. Es así que el enfoque más utilizado se relacionó con EEG (electroencefalograma) + ML (Machine Learning) /DL (Deep Learning). Los modelos fueron las señales EEG, especialmente el análisis de bandas de frecuencia (α , β , θ y δ). Respecto a los algoritmos, se identificó que los más aplicados son Support Vector Machine (SVM), Random Forest y árboles de decisión. Cabe mencionar que, la tendencia hacia modelos explicables (XAI) es una respuesta a necesidades de transparencia para adopción regulatoria y confianza del usuario, pero, se presenta en menor proporción.

2. Por otro lado, se determinó la eficacia de sistemas de IA en la prevención de incidentes o accidentes de tránsito; en el que la validación experimental en laboratorio o simulador presenta precisiones entre 89% y 99,8%. En estudios controlados establecen viabilidad técnica inicial y validan capacidad discriminativa de modelos antes de la implementación práctica, pues eliminan variables confusoras mediante protocolos estandarizados. La implementación en tiempo real durante la conducción alcanza madurez técnica, logrando detección continua con latencias inferiores a 100 milisegundos y precisiones superiores al 95%. Los sistemas basados en visión artificial, sensores portátiles y arquitecturas ligeras de aprendizaje profundo demuestran capacidad de procesamiento inmediato sin afectar la experiencia del conductor.

3. Además, la integración de múltiples sensores en sistemas multimodales mejora la confiabilidad y reduce los falsos positivos. La evidencia de validación en ADAS (Sistemas Avanzados de Asistencia al Conductor) muestra que la fusión de la detección de fatiga con el mantenimiento de carril y el frenado automático multiplica el impacto preventivo. La eficacia

demostrada en la prevención de accidentes justifica la inversión en investigación y desarrollo. Por lo tanto, los resultados experimentales de alta precisión posicionan a sistemas de detección basados en IA como intervención de salud pública con potencial para salvar miles de vidas anualmente.

4. Por último, se establecieron recomendaciones que impulsen el uso de tecnologías de IA aplicadas a la detección de fatiga en conductores, para ello, se revisaron las investigaciones, donde se encontraron sugerencias como el uso de configuraciones de electroencefalograma con un número reducido de electrodos (3-8 canales) para una precisión superior al 90% mientras reduce la intrusividad. Incluyendo el uso de enfoques multimodales mediante la integración de EEG simplificado con visión facial y señales cardíacas mediante fusión jerárquica con mecanismos de atención. Adicionalmente, enfatiza la necesidad de modelos explicables que transparenten el razonamiento interno de los sistemas de IA, como las técnicas de interpretabilidad, para comprender qué variables fisiológicas determinan cada alerta, facilitando la validación clínica y aceptación regulatoria. En la optimización de arquitecturas para inferencia en dispositivos embebidos, consideran a TinyML para democratizar la tecnología; incluso es importante la validación exhaustiva en condiciones reales de conducción antes del despliegue comercial.

5. Cabe mencionar que, la revisión sistemática consolida evidencia dispersa sobre detección de fatiga mediante IA, facilitando la toma de decisiones para investigadores, desarrolladores y formuladores de políticas. Los resultados significan que la tecnología de detección de fatiga basada en IA alcanzó madurez suficiente para la implementación práctica mediante soluciones no invasivas basadas en visión computacional complementadas con sensores portátiles.

4.2 Recomendaciones

1. Desarrollar investigaciones comparativas rigurosas que evalúen múltiples algoritmos bajo protocolos estandarizados, utilizando las mismas bases de datos y condiciones experimentales, con el fin de garantizar resultados reproducibles y comparables.

2. Diseñar arquitecturas híbridas que combinen las fortalezas del aprendizaje profundo con la interpretabilidad de algoritmos clásicos, incluyendo modelos tipo ensemble que integren, por ejemplo, SVM para extracción de características con redes convolucionales.

3. Explorar técnicas avanzadas de aumento de datos específicas para señales electroencefalográficas y faciales, como el uso de redes generativas adversarias (GANs) para sintetizar patrones realistas de fatiga, mejorando la generalización de los modelos sin requerir recolección masiva y costosa de datos reales.

4. Incorporar variables contextuales adicionales —como hora del día, duración de la conducción y condiciones meteorológicas— para fortalecer la capacidad predictiva de los modelos de detección de fatiga.

5. Realizar estudios longitudinales (1–3 años) que evalúen el impacto real de los sistemas de detección de fatiga en la reducción de tasas de accidentalidad en escenarios reales de conducción.

6. Investigar la integración de estos sistemas con infraestructura vial inteligente mediante comunicación vehículo-infraestructura, permitiendo activar señalización dinámica o modificar límites de velocidad cuando múltiples vehículos reporten estados de alta somnolencia en un mismo segmento vial.

7. Analizar factores psicológicos y conductuales que influyen en la adherencia del conductor a las alertas del sistema, desarrollando protocolos estandarizados que simulen condiciones extremas (fatiga severa o privación de sueño mayor a 24 horas) para determinar

límites operacionales de la tecnología y diseñar intervenciones escalonadas según el nivel de riesgo.

8. Actualizar los marcos regulatorios para establecer estándares mínimos de desempeño, certificación y protección de datos biométricos, permitiendo actualizaciones de firmware sin necesidad de recertificación completa.

9. Crear bases de datos públicas multimodales con etiquetado clínicamente validado mediante protocolos estandarizados, favoreciendo la transparencia y el avance científico.

10. Implementar programas de educación pública sobre fatiga vehicular y funcionamiento de sistemas de detección, evaluando sistemáticamente la efectividad de campañas informativas.

11. Evaluar la efectividad diferencial de los sistemas según perfiles demográficos (edad, género, etnia) y condiciones médicas preexistentes (apnea del sueño, uso de medicamentos sedantes, trastornos neurológicos), con el objetivo de avanzar hacia modelos personalizados y estrategias de adaptación intercultural.

12. Analizar la integración con dispositivos portátiles como smartwatches que monitoricen la calidad del sueño nocturno, permitiendo alertas preventivas antes del inicio del viaje y complementando la detección reactiva durante la conducción mediante arquitecturas descentralizadas que protejan la privacidad.

13. Generar benchmarks reproducibles que faciliten la comparación directa entre CNN, LSTM, Transformers y algoritmos clásicos, considerando métricas de precisión, latencia computacional y requerimientos de hardware.

REFERENCIAS

- Abbas, Q., & Alsheddy, A. (2021). Driver Fatigue Detection Systems Using Multi-Sensors, Smartphone, and Cloud-Based Computing Platforms: A Comparative Analysis. *Sensors*, 21(1), 1-38. <https://doi.org/10.3390/s21010056>
- Abieluk, A., & Gutiérrez, C. (2021). Historia y evolución de la inteligencia artificial. *Inteligencia Artificial*, 21(21), 14. <https://doi.org/10.71904/bits.vi21.2767>
- Agencia Nacional de Tránsito. (2021). *estadísticas de siniestros viales en el Ecuador*. ANT: <https://www.ant.gob.ec/>
- Aghamalizadeh, A., Mazloumi, A., Nikabadi, A., Nahvi, A., Khanehshenas, F., & Ebrahimian, S. (2024). Driver Drowsiness is Associated with Altered Facial Thermal Patterns: Machine Learning Insights from a Thermal Imaging Approach. *Physiology & Behavior*, 283(3), 1-25. <https://doi.org/10.1016/j.physbeh.2024.114619>
- Alajlan, N., & Ibrahim, D. (2023). DDD TinyML: A TinyML-Based Driver Drowsiness Detection Model Using Deep Learning. *Sensors*, 23(12), 1-35. <https://doi.org/10.3390/s23125696>
- AlArnaout, Z., Zaki, C., Kotb, Y., AlAkkoum, M., & Mostafa, N. (2025). Exploiting heart rate variability for driver drowsiness detection using wearable sensors and machine learning. *Scientific Reports*, 15, 24898. <https://doi.org/10.1038/s41598-025-08582-2>
- Albadawi, Y., AlRedhaei, A., & Takruri, M. (2023). Real-Time Machine Learning-Based Driver Drowsiness Detection Using Visual Features. *Imaging*, 9(5), 1-18. <https://doi.org/10.3390/jimaging9050091>
- Albadawi, Y., Takruri, M., & Awad, M. (2022). A Review of Recent Developments in Driver Drowsiness Detection Systems. *Sensors*, 22(5), 1-41. <https://doi.org/10.3390/s22052069>

Al-Gburi, S., Al-Sammak, K., Marghescu, I., Oprea, C., Drăgulinescu, A., Alduais, N., . . .

Al-Sammak, N. (2025). EffRes-DrowsyNet: A Novel Hybrid Deep Learning Model Combining EfficientNetB0 and ResNet50 for Driver Drowsiness Detection. *Sensors*, 25(12), 1-36. <https://doi.org/10.3390/s25123711>

Almirón, R., Castillo, B., Montoya, A., Supo, E., Talavera, J., & Yanyachi, D. (2024).

Preventive Detection of Driver Drowsiness from EEG Signals using Fuzzy Expert Systems. *Revista Mexicana de Ingeniería Biomédica*, 45(1), 6-20. <https://doi.org/10.17488/rmib.45.1.1>

Amidei, A., Spinsante, S., Iadarola, G., Benatti, S., Tramarin, F., Pavan, P., & Rovati, L.

(2023). Driver Drowsiness Detection: A Machine Learning Approach on Skin Conductance. *Sensors*, 23(8), 1-18. <https://doi.org/10.3390/s23084004>

Ardabili, S., Bahmani, S., Lahijan, L., Khaleghi, N., Sheykhivand, S., & Danishvar, S.

(2024). A Novel Approach for Automatic Detection of Driver Fatigue Using EEG Signals Based on Graph Convolutional Networks. *Sensors*, 24(2), 364. <https://doi.org/10.3390/s24020364>

Arif, S., Munawar, S., & Ali, H. (2023). Driving drowsiness detection using spectral

signatures of EEG-based neurophysiology. *Frontiers in Physiology*, 30(14), 1-13. <https://doi.org/10.3389/fphys.2023.1153268>

Bajaj, J., Kumar, N., Kaushal, R., Gururaj, H., Flammini, F., & Natarajan, R. (2023). System

and Method for Driver Drowsiness Detection Using Behavioral and Sensor-Based Physiological Measures. *Sensors*, 23(3), 1-19. <https://doi.org/10.3390/s23031292>

Bencsik, B., Reményi, I., Szemenyei, M., & Botzheim, J. (2023). Designing an Embedded

Feature Selection Algorithm for a Drowsiness Detector Model Based on Electroencephalogram Data. *Sensors*, 23, 1-22. <https://doi.org/10.3390/s23041874>

- Cao, S., Feng, P., Kang, W., Chen, Z., & Wang, B. (2025). Optimized driver fatigue detection method using multimodal neural network. *Scientific Reports*, *15*, 1-26.
<https://doi.org/10.1038/s41598-025-86709-1>
- Castellón, L., Olascoaga, N., Carriazo, L., Castrillón, C., & Severiche, C. (2024). Herramientas de inteligencia artificial para sistemas de seguridad y salud en el trabajo. *Metaverse Basic and Applied Research*, *3*, 1-8.
<https://doi.org/10.56294/mr2024.129>
- Chen, C., Liu, X., Zhou, M., Li, Z., Du, Z., & Lin, Y. (2025). Lightweight and Real-Time Driver Fatigue Detection Based on MG-YOLOv8 with Facial Multi-Feature Fusion. *Journal of Imaging*, *11*(11), 1-25. <https://doi.org/10.3390/jimaging11110385>
- Cho, Y., Nazarov, F., Xamidov, M., Turimov, D., & Makhmudov, F. (2024). Real-Time Fatigue Detection Algorithms Using Machine Learning for Yawning and Eye. *Italian National Conference on Sensors*, *24*, 7810.
<https://doi.org/https://doi.org/10.3390/s24237810>
- Codina, L. (2020). Cómo hacer revisiones bibliográficas tradicionales o sistemáticas utilizando bases de datos académicas. *Revista ORL*, *11*(2), 139–153, *11*(2), 139-153.
<https://doi.org/10.14201/orl.22977>
- Cui, J., Lan, Z., Liu, Y., Li, R., Li, F., Sourina, O., & Müller, W. (2022). A Compact and Interpretable Convolutional Neural Network for Cross-Subject Driver Drowsiness Detection from Single - Chanel EEG. *Methods*, *202*, 173-184.
<https://doi.org/10.1016/j.ymeth.2021.04.017>
- Duarte, R., Bueno, L., & Souza, A. (2023). Los efectos de la fatiga en los conductores de camiones en el transporte de carga. *Interciencia: Revista de ciencia y tecnología de América*, *48*(5), 228-235. <https://dialnet.unirioja.es/servlet/articulo?codigo=8985983>

- Essahraoui, S., Lamaakal, I., El Hamly, I., Maleh, Y., Ouahbi, I., El Makkaoui, K., . . . Abd, A. (2025). Real-Time Driver Drowsiness Detection Using Facial Analysis and Machine Learning Techniques. *Sensors*, 25(3), 1-22. <https://doi.org/10.3390/s25030812>
- Essahraoui, S., Lamaakal, I., Maleh, Y., K, M., Bouami, M., Ouahbi, I., . . . Abd El-Latif, A. (2025). FastKAN-DDD: A novel fast Kolmogorov-Arnold network-based approach for driver drowsiness detection optimized for TinyML deployment. *PLoS One*, 20(11), 1-21. <https://doi.org/10.1371/journal.pone.0332577>
- Feng, L., Kang, W., Cao, S., & Huang, W. (2025). Optimized driver fatigue detection method using multimodal neural networks. *Scientific Reports*, 15(1), 1-27. <https://doi.org/10.1038/s41598-025-86709-1>
- Flores, J., Nakano, M., Escamilla, E., & Pérez, H. (2023). Detección de somnolencia y distracción en conductores y su implementación en dispositivos móviles. *Información Tecnológica*, 34(4), 1-12. <https://doi.org/10.4067/S0718-07642023000400001>
- Florez, R., Palomino, F., Alvarez, A., Coaquira, R., & Herrera, J. (2024). A Real-Time Embedded System for Driver Drowsiness Detection Based on Visual Analysis of the Eyes and Mouth Using Convolutional Neural Network and Mouth Aspect Ratio. *Sensors*, 24, 1-27. <https://doi.org/10.3390/s24196261>
- Florez, R., Palomino, F., Coaquira, R., Herrera, J., Paixão, T., & Alvarez, A. (2023). A CNN-Based Approach for Driver Drowsiness Detection by Real-Time Eye State Identification. *Applied Sciences*, 13(13), 1-18. <https://doi.org/10.3390/app13137849>
- Galvez, C. (2024). Mapa científico de la Inteligencia Artificial en Comunicación (2004-2024). *European Public & Social Innovation Review*, 9, 1-17. <https://doi.org/10.31637/epsir-2024-947>
- Gómez, J., & Cuartas, M. (2020). Accidentalidad vial: efectos de la calidad del sueño en el funcionamiento ejecutivo de conductores de transporte público urbano. *Revista de*

investigación e innovación en ciencias de la salud, 2(1), 41-55.

<https://doi.org/10.46634/riics.43>

Guevara, G., Verdesoto, A., & Castro, N. (2020). Metodologías de investigación educativa (descriptivas, experimentales, participativas, y de investigación-acción).

RECIMUNDO: Revista Científica de la Investigación y el Conocimiento, 4(3), 163-173. <https://dialnet.unirioja.es/servlet/articulo?codigo=7591592>

Hasan, M., Watling, C., & Larue, G. (2022). Physiological signal-based drowsiness detection using machine learning: Singular and hybrid signal approaches. *Journal of Safety Research*, 80, 215-225. <https://doi.org/10.1016/j.jsr.2021.12.001>

Hasan, M., Watling, C., & Larue, G. (2024). Validation and interpretation of a multimodal drowsiness detection system using explainable machine learning. *Computer Methods and Programs in Biomedicine*, 243, 1-16. <https://doi.org/10.1016/j.cmpb.2023.107925>

Hassan, J., Naziullah, S., Rashid, M., Islam, T., Islam, N., Islam, S., & Mahmud, S. (2025). Current status and challenges in electroencephalography (EEG)-based driver fatigue detection: a comprehensive survey. *Cognitive Neurodynamics*, 19(142), 1-38. <https://doi.org/10.1007/s11571-025-10320-3>

Hassan, O., Ibrahim, A., Gomaa, A., Makhlof, M., & Hafiz, B. (2025). Real-time driver drowsiness detection using transformer architectures: a novel deep learning approach. *Scientific Reports*, 15(17), 17493. <https://doi.org/10.1038/s41598-025-02111-x>

Hong, S., & Baek, H. (2021). Drowsiness Detection Based on Intelligent Systems with Nonlinear Features for Optimal Placement of Encephalogram Electrodes on the Cerebral Area. *Sensors*, 21, 1-16. <https://doi.org/10.3390/s21041255>

Hussein, R. M. (2023). Driver drowsiness detection methods using EEG signals: a systematic review. *Computer Methods in Biomechanics and Biomedical Engineering*, 26(11), 1237-1249. <https://doi.org/10.1080/10255842.2022.2112574>

INEC. (2025). *Estadísticas de Transporte (ESTRA) Siniestros de Tránsito I Trimestre, 2025*.

Instituto Ecuatoriano de Estadísticas y Censos.

<https://www.ecuadorencifras.gob.ec/documentos/web->

[inec/Estadisticas_Economicas/Estadistica%20de%20Transporte/2025/i_trimestre/2025_RESULTADOS_SINIESTROS_IT.pdf](https://www.ecuadorencifras.gob.ec/documentos/web-inec/Estadisticas_Economicas/Estadistica%20de%20Transporte/2025/i_trimestre/2025_RESULTADOS_SINIESTROS_IT.pdf)

Izurieta, P., Vega, S., Maldonado, S., & Delgado, M. (2024). Análisis de intervenciones de Seguridad Vial para reducir accidentes de tránsito en Ecuador. *Revista Tecnológica - ESPOL*, 36(2), 112-134. <https://doi.org/10.37815/rte.v36n2.1182>

Jinez, J., Ortiz, P., Erazo, J., & Toasa, R. (2025). Desarrollo de un sistema de alerta para la prevención de accidentes de tránsito mediante reconocimiento de señales y visión artificial. *Ciencia Y Educación*, 6(3), 6-18. <https://doi.org/10.5281/zenodo.14976012>

Kakhi, K., Kumar, S., Khosravi, A., Alizadehsani, R., & Acharya, R. (2025). Fatigue monitoring using wearables and AI: Trends, challenges, and future opportunities. *Computers in Biology and Medicine*, 195, 1-34.

<https://doi.org/10.1016/j.compbimed.2025.110461>

Khanehshenas, F., Mazloumi, A., Nahvi, A., Nickabadi, A., Sadeghniaat, K., Rahimiforoushani, A., & Aghamalizadeh, A. (2024). A hybrid approach for driver drowsiness detection utilizing practical data to improve performance system and applicability. *Work*, 77(4), 1165-1177. <https://doi.org/10.3233/WOR-230179>

Kiruba, P., & Sofia, S. (2025). An Explainable Artificial Intelligence (XAI) Based Driver Fatigue Detection System For Safe And Care Human Life (SCHL). *International Journal of Environmental Sciences*, 11(8), 839-855.

<https://doi.org/10.64252/b1waxa37>

- Li, G., & Chung, W. (2022). Electroencephalogram-Based Approaches for Driver Drowsiness Detection and Management: A Review. *Sensors*, 23(3), 1-26.
<https://doi.org/10.3390/s22031100>
- Lin, C., Zhu, X., Wang, R., Zhou, W., Li, N., & Xie, Y. (2025). Early Driver Fatigue Detection System: A Cost-Effective and Wearable Approach Utilizing Embedded Machine Learning. *Vehicles*, 7(1), 1-25. <https://doi.org/10.3390/vehicles7010003>
- Liu, G., Wu, K., Lan, W., & Wu, Y. (2025). YOLO-FDCL: Improved YOLOv8 for Driver Fatigue Detection in Complex Lighting Conditions. *Sensors*, 25(15), 1-23.
<https://doi.org/10.3390/s25154832>
- Magán, E., Sesmero, M., Alonso, J., & Sanchis, A. (2022). Driver Drowsiness Detection by Applying Deep Learning Techniques to Sequences of Images. *Applied Sciences*, 12(3), 1-25. <https://doi.org/10.3390/app12031145>
- Makhmudov, F., Turimov, D., Xamidov, M., Nazarov, F., & Cho, Y. (2024). Real-Time Fatigue Detection Algorithms Using Machine Learning for Yawning and Eye State. *Sensors*, 24(23), 1-14. <https://doi.org/10.3390/s24237810>
- Malik, M., Sharma, P., Punj, G., Singh, S., & Gared, F. (2025). Multi-body sensor based drowsiness detection using convolutional programmed transfer VGG-16 neural network with automatic driving mode conversion. *Scientific Reports*, 15, 1-13.
<https://doi.org/10.1038/s41598-025-89479-y>
- Mu, Z., Yin, J., Jin, L., & Wang, Q. (2022). Application of Graph Neural Network in Driving Fatigue Detection Based on EEG Signals. *Computational Intelligence and Neuroscience*, 2, 1-10. <https://doi.org/10.1155/2022/9775784>
- Muñoz, E., Verduga, D., Alcívar, G., Lapo, M., & Zorrilla, O. (2024). Búsqueda de Patrones con Machine Learning en Datos de Siniestros de Tránsito. *Ciencia Latina Revista*

Científica Multidisciplinar, 8(2), 1617-1638.

https://doi.org/10.37811/cl_rcm.v8i2.10592

Murugan, S., Sivakumar, P., Kavitha, C., B, A., & Lai, W. (2023). An Electro-Oculogram (EOG) Sensor's Ability to Detect Driver Hypovigilance Using Machine Learning. *Sensors*, 23(6). <https://doi.org/10.3390/s23062944>

Noroña, D., & Vega, V. (2022). Fatiga laboral percibida en conductores de compañías de transporte de Orellana, Pichincha y Guayas. *Revista Médica Electrónica*, 44(4), 652-667. <https://www.redalyc.org/journal/3782/378277403003/html/>

Ochoa, J., & Yunkor, Y. (2021). El estudio descriptivo en la investigación científica. *Acta Jurídica Peruana*, 2(2), 1-19.

<http://revistas.autonoma.edu.pe/index.php/AJP/article/view/224>

Oviedo, B., López, E., Guevara, P., & Carpio, D. (2025). Epidemiología de los accidentes de tránsito en Ecuador: un enfoque en la tecnología y la seguridad vial. *REMCA*, 8(S1), 148-153. <https://doi.org/10.62452/vb2rr283>

Page, M., McKenzie, J., Bossuyt, P., Boutron, I., Hoffmann, T., Cynthia Mulrow, L. S., . . .

Glanville, J. (2021). Declaración PRISMA 2020: una guía actualizada para la publicación de revisiones sistemáticas. *Rev Esp Cardiol*, 74(9), 790-799.

<https://doi.org/https://doi.org/10.1016/j.recesp.2021.06.016>

Paredes, P., Cisneros, G., & Paredes, J. (2024). Inteligencia Artificial: ¿De dónde viene y hacia dónde puede ir? *Koyuntura*, 2(110), 1-16.

<https://www.usfq.edu.ec/sites/default/files/2025-04/koyuntura-version-2-abril-2025.pdf>

Peivandi, M., Ardabili, S., Sheykhivand, S., & Danishvar, S. (2023). Deep Learning for Detecting Multi-Level Driver Fatigue Using Physiological Signals: A Comprehensive Approach. *Sensors*, 23(19), 1-23. <https://doi.org/10.3390/s23198171>

- Pérez, K. (2025). *La fatiga de los conductores es un problema frecuente en EE.UU.*
KennyPerezLae: <https://kennyperezlaw.com/es/driver-fatigue-is-a-prevalent-problem/>
- Rayani, M., Ghimatgar, H., & Mansorinejad, M. (2025). EEG quantization and entropy of multi-step transition probabilities for driver drowsiness detection via LSTM. *Computers in Biology and Medicine*, 196.
<https://doi.org/10.1016/j.combiomed.2025.110758>
- Rezaee, K., Nazerian, A., Ghayoumi, H., Attar, H., Khosravi, M., & Kanan, M. (2025). Smart IoT-driven biosensors for EEG-based driving fatigue detection: A CNN-XGBoost model enhancing healthcare quality. *BioImpacts*, 15, 1-15.
<https://doi.org/10.34172/bi.30586>
- Saleem, A., Siddiqui, H., Raza, M., Rustam, F., Dudley, S., & Ashraf, I. (2024). A systematic review of physiological signals based driver drowsiness detection systems. *Cognitive Neurodynamics*, 17(5), 1229-1259. <https://doi.org/10.1007/s11571-022-09898-9>
- Samerei, S., & Aghabayk, K. (2024). Interpretable machine learning for evaluating risk factors of freeway crash severity. *International Journal of Injury Control and Safety Promotion*, 31(3), 534–550. <https://doi.org/10.1080/17457300.2024.2351972>
- Serrano, L., Onieva, E., Landaluce, H., Masegosa, A., & Moreno, A. (2019). *¿Cómo puede la inteligencia artificial reducir los accidentes de tráfico y evitar atascos?* DEUSTO.
<https://www.deusto.es/document/research/es/inteligencia-artificial.pdf>
- Siddiqui, H., Akmal, A., Iqbal, M., Saleem, A., Raza, M., Zafar, K., . . . Rustam, F. (2024). Ultra-Wide Band Radar Empowered Driver Drowsiness Detection with Convolutional Spatial Feature Engineering and Artificial Intelligence. *Sensors*, 24(12), 1-21.
<https://doi.org/10.3390/s24123754>

- Siddiqui, H., Saleem, A., Brown, R., Bademci, B., Lee, E., Rustam, F., & Dudley, S. (2021). Non-Invasive Driver Drowsiness Detection System. *Sensors*, *21*(14), 1-17.
<https://doi.org/10.3390/s21144833>
- Stancin, I., Cifrek, M., & Jovic, A. (2021). A Review of EEG Signal Features and Their Application in Driver Drowsiness Detection Systems. *Sensors*, *21*(11), 1-29.
<https://doi.org/10.3390/s21113786>
- Stancin, I., Frid, N., Cifrek, M., & Jovic, A. (2021). EEG Signal Multichannel Frequency-Domain Ratio Indices for Drowsiness Detection Based on Multicriteria Optimization. *Sensors*, *21*, 1-23. <https://doi.org/10.3390/s21206932>
- Sun, M., Zhou, R., Jiao, C., & Sun, X. (2022). Severity Analysis of Hazardous Material Road Transportation Crashes with a Bayesian Network Using Highway Safety Information System Data. *International Journal Environmental Research and Public Health*, *19*(7), 1-22. <https://doi.org/10.3390/ijerph19074002>
- Tarafder, S., Badruddin, N., Yahya, N., & Nasution, A. (2022). Drowsiness Detection Using Ocular Indices from EEG Signal. *Sensors*, *22*(13), 1-17.
<https://doi.org/10.3390/s22134764>
- Theivadas, R., & Ponnann, S. (2025). Deep-ATM DL-LSTM: A novel adaptive thresholding model with dual-layer LSTM architecture for real-time driver drowsiness detection using skin conductance signals. *Computers in Biology and Medicine*, *192*.
<https://doi.org/10.1016/j.combiomed.2025.110243>
- Vaca, L., & Sánchez, L. (2025). Uso de la Inteligencia Artificial (IA), aplicada al transporte público del cantón Santo Domingo, Provincia Santo Domingo de los Tsáchilas, año 2024. *Código Científico Revista De Investigación*, *6*(E1), 386-407.
<https://doi.org/10.55813/gaea/ccri/v6/nE1/693>

Zayed, A., Belhadj, N., Ben Khalifa, K., Bedoui, M., & Valderrama, C. (2024). Efficient Generalized Electroencephalography-Based Drowsiness Detection Approach with Minimal Electrodes . *Sensors*, *24*, 1-34. <https://doi.org/10.3390/s24134256>

Zeng, C., Zhang, J., Su, Y., Li, S., Wang, Z., Li, Q., & Wang, W. (2024). Driver Fatigue Detection Using Heart Rate Variability Features from 2-Minute Electrocardiogram Signals While Accounting for Sex Differences. *Sensors*, *24*(13), 1-14. <https://doi.org/10.3390/s24134316>

Zeng, H., Zhang, J., Zakaria, W., Babiloni, F., Gianluca, B., Li, X., & Kong, W. (2020). InstanceEasyTL: An Improved Transfer-Learning Method for EEG-Based Cross-Subject Fatigue Detection. *Sensors*, *20*(24), 1-17. <https://doi.org/10.3390/s20247251>

Apéndice A

Enfoque identificado	N de artículos	%	Artículos (N)
EEG + ML/DL	18	31,58%	3, 6, 9, 14, 15, 25, 30, 31, 33, 35, 38, 39, 41, 45, 49, 54, 57
Visión por computador	12	21,05%	4, 21, 24, 32, 36, 42, 46, 47, 52, 53, 56
Señales fisiológicas (ECG, HRV, SC)	8	14,04%	11, 16, 20, 29, 34, 54
Sistemas multimodales	10	17,54%	1, 2, 18, 22, 26, 28, 37, 44, 55
TinyML / IoT / XAI	9	15,79%	1, 8, 37, 40, 43, 45, 48, 50
Total	57	100%	

Modalidad / Característica	Frecuencia (n)	%	Artículos (N)
EEG: Bandas de frecuencia (α , β , θ , δ)	24	42%	3, 6, 7, 9, 10, 14, 15, 25, 30, 31, 33, 34, 35, 38, 39, 41, 45, 49, 51, 54, 55, 57
EEG: Índices de potencia espectral	18	32%	6, 9, 14, 15, 25, 30, 33, 35, 38, 41, 49, 51, 54, 55, 57
EEG: Índices de relación de frecuencias	14	25%	3, 6, 9, 15, 25, 30, 33, 35, 38, 41, 51, 54, 57
EEG: Heart Rate Variability (HRV)	8	14%	2, 11, 20, 29, 34, 51, 54, 55
Visual: PERCLOS	16	28%	4, 13, 21, 22, 32, 36, 40, 42, 46, 47, 53, 56
Visual: Eye Aspect Ratio (EAR)	18	32%	4, 13, 21, 22, 32, 36, 40, 42, 46, 47, 53, 56
Visual: Mouth Aspect Ratio (MAR)	12	21%	4, 21, 32, 36, 46, 47, 53
Visual: Head Pose Rotation (HPR)	9	16%	22, 32, 36, 46, 47, 53
Visual: Frecuencia de parpadeo	14	25%	4, 13, 21, 22, 32, 35, 36, 40, 42, 46, 47, 53, 56
Visual: Frecuencia de bostezo	13	23%	4, 13, 22, 32, 36, 40, 42, 46, 47, 53, 56
EOG: Índices oculares	3	5%	23, 35
Skin Conductance: Señales galvánicas	5	9%	11, 16, 20, 48

Algoritmo	Frecuencia (n)	Algoritmo	Precisión Media	Artículos (N)
Support Vector Machine (SVM)	15	26%	91,80%	6, 7, 9, 19, 20, 23, 29, 30, 35, 37, 41, 48
Random Forest	9	16%	90,50%	12, 19, 20, 27, 29, 37, 48, 54
Decision Trees	12	21%	89,70%	1, 12, 19, 20, 27, 35, 37, 48, 54
k-Nearest Neighbors (KNN)	8	14%	88,30%	7, 19, 20, 29, 37, 48
Multi-Layer Perceptron (MLP)	6	11%	92,40%	19, 30, 37
XGBoost	4	7%	94,60%	29, 45, 48
Naive Bayes	3	5%	86,20%	19, 20, 48
Total	57	100%	90,50%	

Apéndice B

Evidencia de eficacia

Tipo de estudio	N de artículos	%	Artículos (N)
Experimental (laboratorio/simulador) / Accuracy 89–99.8 %, p < 0.05	13	23%	2, 6, 11, 25, 30, 31, 34, 35, 37, 39, 41, 45, 57
Tiempo real (cabina / wearable) / Precisión > 95 %, baja latencia	9	16%	4, 13, 21, 26, 29, 40, 50, 52, 56
Validación en condiciones reales / Reducción de errores y alta robustez	6	11%	18, 22, 29, 44, 48, 50
Total	28	49%	

Apéndice C

Recomendaciones fundamentadas por evidencia

Evidencia encontrada	N de artículos	%	Recomendación	Artículos (N)
Alta precisión EEG con pocos sensores	6	11%	Usar EEG de bajo número de electrodos	3, 6, 25, 30, 45, 57
Mayor robustez multimodal	3	5%	Integrar señales fisiológicas y visuales	2, 18, 37
Necesidad de confianza y adopción	3	5%	Incorporar modelos explicables (XAI)	1, 37, 39
Viabilidad en IoT y vehículos	3	5%	Priorizar TinyML y modelos ligeros	40, 43, 50
Éxito visión computarizada	4	7%	Usar visión en contextos no invasivos	4, 21, 32, 56
Validación real	3	5%	Priorizar estudios en carretera	13, 26, 29
Total	22	39%		