

Recibido 11 Agos 2025

ReCIBE, Año 15 No. 1, mayo 2026

Aceptado 30 Nov 2025

Método Eye tracking en la detección de somnolencia en conductores: Una revisión de literatura

Eye tracking method in detecting drowsiness in drivers: A literature review

Martin Laguna Estrada ¹

martin.laguna@itcelaya.edu.mx

José Manuel Delgado Pérez¹

M2403045@itcelaya.edu.mx

Norma Verónica Ramírez Pérez¹

norma.ramirez@itcelaya.edu.mx

Luis Alberto López Gonzalez¹

luislao@celaya.tecnm.mx

Juan Ignacio Cerca Vázquez¹

nacho@itcelaya.edu.mx

José Manuel Malagon Soldara¹

salvador.malagon@itcelaya.edu.mx

1 Instituto Tecnológico de Celaya

Resumen

En la presente investigación se realiza una revisión de literatura relacionada con el uso del método de Eye Tracking (ET) o seguimiento ocular, para la detección, obtención y análisis de perfiles de somnolencia, el cual es uno de los factores de riesgo más presente en todo tipo de conductores, aumentando la probabilidad de causar accidentes. Para llevar a cabo esta revisión se utilizó la metodología PRISMA versión 2020, que permite realizar una investigación exhaustiva a través de la identificación, filtrado, elegibilidad e inclusión de los artículos que abordan la detección de somnolencia en los conductores. Como resultado del trabajo realizado, se elaboró una tabla de doble entrada de los estudios consultados en artículos científicos publicados en revistas de alto impacto, limitado a aquellos de reciente data período 2019 al 2025 con pertinencia y actualización de datos además de un aporte de evidencias empíricas en torno al objeto de estudio.

Palabras clave: Eye tracking; Somnolencia; Red neuronal; Deep learning; Procesamiento de imágenes.

Abstract

In the present study, a literature review was conducted on the use of the Eye-tracking method (ET) for detecting, obtaining, and analyzing driver fatigue profiles, one of the most prevalent risk factors among all kinds of drivers, which increases the likelihood of causing accidents. To carry out this review, the PRISMA 2020 methodology was employed, enabling a thorough investigation through the identification, screening, eligibility assessment, and inclusion of articles addressing driver drowsiness and fatigue detection. As a result, a two-way table was developed summarizing the consulted studies, drawn from scientific articles published in high impact journals, limited to those with recent publication dates from 2019 to 2025, relevant and up to date data, and empirical evidence contributions related to the study's focus.

Keywords: Eye tracking; Drowsiness; Neural network; Deep learning; Image processing.

1. Introducción

De acuerdo con Zhang et al. (2017, citado en Jasim et al., 2022), es importante garantizar a los pasajeros un viaje seguro, por lo que proteger la vida del conductor y del pasajero requiere una mejora constante en la seguridad al conducir. Como plantean You et al. (2020), entre los factores de riesgo que inciden en la seguridad se encuentra la somnolencia de los conductores. El propósito de mejorar la seguridad lleva a investigar y utilizar aplicaciones o sistemas de detección de somnolencia eficientes e innovadores como medida crucial para la prevención de accidentes.

En este mismo orden de ideas, Satapathy et al. (2023) sostienen que la somnolencia del conductor ha sido una de las mayores causas de accidentes de tráfico ocasionando muertes y lesiones graves. Afirman que se contabiliza un aproximado de más de un millón de personas que murieron en todo el mundo por este tipo de accidentes. Cuando un conductor se siente fuertemente cansado y con una necesidad alta de dormir, el conducir bajo este síntoma se le llama somnolencia del conductor y entre los factores que la producen se encuentran: la falta de sueño, consumo de alcohol o de medicamentos.

Chirra et al. (2019) explican que el trabajo realizado por agentes de policía y patrullaje ha revelado que mayoritariamente los accidentes registrados se producen entre las 2 y 5 am, siendo uno de los factores predisponentes el no dormir bien. Esto verifica la necesidad de mejorar las tecnologías que detectan la somnolencia para reducir el número de accidentes viales. Debido a las razones expuestas, se hace necesario identificar sistemas que alerten a los conductores permitiendo minimizar los accidentes de tránsito a la vez que se preserva la vida de las personas y las propiedades públicas. Uno de los métodos de detección de somnolencia, es el estudio del seguimiento ocular, el cual se ha utilizado

en múltiples campos de la investigación como una herramienta que permite obtener respuestas a diversas interrogantes.

La presente investigación se justifica por el creciente número de siniestros viales en los que la somnolencia del conductor provoca consecuencias adversas para pasajeros además de peatones y mobiliario presente en la zona. La Organización Mundial de la Salud (OMS, 2023) estima una cifra de entre 20 y 50 millones de personas que resultan heridas debido a accidentes vehiculares, de las cuales, al menos 1.19 millones de personas pierden la vida. A nivel nacional, el Instituto Nacional de Estadística y Geografía (INEGI, s. f.) reportó un total de 374,949 accidentes viales. La relación de este tipo de accidentes con la somnolencia ha sido vinculada en investigaciones como la desarrollada por la AAA Foundation for Traffic Safety (2024) localizada en Estados Unidos, en la cual se llega a la conclusión de que, al menos en un 17.8 % de los accidentes donde alguno de los pasajeros pierde la vida, hubo un conductor con síntomas de somnolencia involucrado.

La relevancia social de la presente investigación se demuestra porque desde un nivel práctico, sirve para dar a conocer los métodos más eficaces que se han identificado en la actualidad, y a la vez, que permite concientizar a la sociedad sobre la importancia de prevenir accidentes, identificando la somnolencia del conductor por medio de la detección de movimiento ocular con métodos eficientes.

En el ámbito profesional, se justifica como una oportunidad y un desafío para los ingenieros en Sistemas, Mecatrónicos e ingenieros en Electromovilidad entre otros, para conocer y mejorar la metodología utilizada actualmente en la detección de la somnolencia en los conductores, siendo el presente estudio una base para mejorar las investigaciones realizadas. El objetivo de esta revisión fue analizar la efectividad del método ET para la obtención y análisis de perfiles de somnolencia en conductores, a través de identificar las evidencias científicas actuales relacionadas a la utilización de este método.

2. Metodología

El presente trabajo de investigación se realizó bajo la modalidad de revisión sistemática, en la búsqueda de referentes teóricos que aportaron evidencias empíricas mediante la utilización del método ET para identificar la somnolencia en los conductores.

Los criterios de inclusión fueron establecidos con el propósito integrar investigaciones útiles para evaluar el panorama actual mediante el uso de la metodología ET para la detección de somnolencia. Se utilizó como criterio el tiempo de publicación entre 2019 y 2025 para contar con investigaciones de carácter reciente. Los trabajos incluidos debían contar con evidencia de los resultados obtenidos en la investigación que fueran congruentes con el resto de la metodología aplicada y debían provenir de publicaciones de alto impacto. Se excluyeron aquellos trabajos que no contaban explícitamente con un autor. En la tabla 1 se muestran todos los criterios tomados en cuenta para la selección de investigaciones.

Categoría	Criterios de Inclusión	Criterios de Exclusión
Publicación	Artículos científicos publicados en revistas de alto impacto.	Artículos sin identificación de autoría.
Temporalidad	Artículos publicados en el período 2019 - 2025.	Artículos publicados con anterioridad al año 2018.
Relevancia y Contenido	Pertinencia y actualización de los datos del estudio.	Investigaciones que no muestren evidencia explícita de los hallazgos encontrados.

	Artículos que aporten evidencias empíricas directas en torno al objeto de estudio.	
--	--	--

Tabla 1. Criterios de inclusión para las investigaciones seleccionadas

2.1 Pregunta P.I.C.O

Aunque la metodología PRISMA 2020 es una buena herramienta para nuestra investigación, consideramos importante la elaboración de la pregunta P.I.C.O aplicando el nemotécnico PICO_R, el cual nos ayuda a dar claridad en la investigación, es centrada en los elementos más relevantes. Lo anterior se representa en la tabla 2.

P: Pacientes	Conductores
I: Intervención	Método Eye tracking
C: Comparación	Somnolencia y estado de alerta
O: Resultados	Efectividad del método

Tabla 2. Nemotécnico PICO_R aplicado a la elaboración de la pregunta P.I.C.O

Se considera la siguiente pregunta PICO (patient, intervention, comparison, outcome) para la realización de la presente revisión sistemática: En conductores de vehículos ¿Cuál es la efectividad del método ET para detectar la somnolencia?

La figura 1 muestra en forma gráfica de barras el total de estudios por etapa.




Figura 1. Gráfica derivada de la selección de literatura

2.2 Evaluación de la calidad

Se realizó una búsqueda en bases de datos consideradas de gran confiabilidad como: Pubmed, Cochrane, Scholar, Scielo y ScienceDirect entre otras. Las ecuaciones de búsqueda utilizadas fueron las siguientes: «Eye tracking * method to determine fatigue in drivers». En cuanto al uso de los booleanos (AND, OR Y NOT) los términos utilizados para realizar la búsqueda fueron: " Eye tracking " OR " determine fatigue in drivers "AND " method * lográndose encontrar 102 artículos vinculados con una combinación de operadores booleanos (AND), seleccionándose finalmente 20 literaturas como se muestra en el flujograma de artículos científicos.

2.3 Extracción de datos

Los datos considerados de relevancia para el estudio fueron extraídos con la colaboración de dos revisores distintos y categorizados tomando en cuenta el tema y objetivo de la investigación.

2.4 Análisis y síntesis de los datos

El estudio contó al final del proceso con 20 artículos científicos para la elaboración de la síntesis de datos, realizando un análisis a profundidad y la extracción de los temas analíticos. En base a los objetivos de investigación y las limitaciones impuestas para la inclusión de estudios se desarrolló la tabla 3 que reúne las principales características de los artículos seleccionados.

Título de artículo	Autor	Revista, Factor de Impacto País	Tamaño muestra Tipo de estudio	Duración de experimento
R2DS: A novel hierarchical framework for driver fatigue detection in mountain freeway	You F, Gong YB, Li XL, Wang HW. (2020).	Revista: Math Biosci Eng Factor de impacto: 0.48 País: China	No indica Tipo de estudio: Experimental	No indica
Driver Drowsiness Detection Using Gray Wolf Optimizer Based on Face and Eye Tracking	Jasim, S. S., Hassan, A. K. A. y Turner, S. (2022)	Revista: Aro-The Scientific Journal of Koya University País: Irak	17 personas de diversas nacionalidades Tipo de estudio: Experimental	No indica
Deep CNN: A Machine Learning Approach for Driver Drowsiness Detection Based on Eye State	Chirra, V. R. R., Uyyala, S. R. y Kolli, V. K. K. (2019)	Revista: Revue d'Intelligence Artificielle Factor de impacto: 0.28 País: India	20 conductores Tipo de estudio: Experimental	No indica
Driver Drowsiness Detection	Ablahd, A. Z., Aloraibi, A. Q., Dawwod, S. A.	Revista: Scalable Computing: Practice and Experience	3000 imágenes (1500 “drowsy” y 1500 “alert”)	No indica

	(2024)	Factor de impacto: 1.1 País: Rumania	Tipo de estudio: Experimental	
Automated Drowsiness Detection for Driver Safety: A Deep Learning-based Approach	Satapathy, S. K., Mori, H., Naik, K., Rajput, N. S. (2023)	Revista/conferencia: 2023 International Conference on Computational Intelligence and Sustainable Engineering Solutions País: India	No indica Tipo de estudio: Experimental	No indica
Una propuesta de Adaptación del Cuestionario de Síntomas de Fatiga Laboral	Vega-Valero, C. Z. (2019)	Revista: Revista de Psicología y Ciencias del Comportamiento de la Unidad Académica de Ciencias Jurídicas y Sociales País: México	250 trabajadores de distintas áreas (muestra final tras pilotaje) Tipo de estudio: Experimental	No indica
A CNN Based Wearable System for Driver Drowsiness Detection	Li, Y., Zhang, S., Zhu, G., Huang, Z., Wang, R., Duan, X., Wang, Z. (2023)	Revista: Sensors Factor de impacto: 3.4 País: China	3 personas Tipo de estudio: Experimental	Las pruebas se llevaron a cabo en periodos de 15 minutos, no se menciona la fecha ni hora de la realización del experimento.
Evaluation of a Fatigue Detector Using Eye Closure-Associated Indicators Acquired from Truck Drivers in a Simulator Study	Dziuda, Ł., Baran, P., Zieliński, P., Murawski, K., Dziwosz, M., Krej, M., Piotrowski, M., Stablewski, R., Wojdas, A., Strus, W., Gasiul, H., Kosobudzki, M. y Bortkiewicz, A. (2021)	Revista: Sensors Factor de impacto: 3.4 País: Polonia	8 personas Tipo de estudio: Experimental	Las pruebas se llevaron a cabo en un periodo de 48 minutos por conductor, no se mencionan fechas ni horas específicas
Driver drowsiness multi-method detection for vehicles with autonomous driving functions.	Beles, H., Vesselenyi, T., Rus, A., Mitran, T., Scurt, F. B, Tolea, B. A. (2024)	Revista: Sensors Factor de impacto: 3.4 País: Rumania	Una persona Tipo de estudio: Experimental	se realizaron cuatro jornadas de manejo con tiempos finales variables, todas realizadas en la mañana y concluidas antes de las 15:00pm

Driver Fatigue Detection Method Based on Eye States With Pupil and Iris Segmentation	Zhuang, Q., Zhang, K., Wang, J. y Chen, Q. (2020)	Revista: IEEE Access Factor de impacto: 3.367 País: China	Dataset de video con 4 videos de validación y 4 de prueba Tipo de estudio: Experimental	No indica
Eye Aspect Ratio for Real-Time Drowsiness Detection to Improve Driver Safety	Dewi, C., Chen, R.-C., Chang, C.-W., Wu, S.-H., Jiang, X., Yu, H. (2022)	Revista: Electronics Factor de impacto: 2.6 Países: Indonesia, Taiwán, Alemania, Reino Unido	15 663 fotogramas totales (TalkingFace: 5 000; Eyeblink8: 10 663) Tipo de estudio: Experimental	No indica
A CNN-Based Approach for Driver Drowsiness Detection by Real-Time Eye State Identification	Florez, R., Palomino-Quispe, F., Coaquira-Castillo, R. J., Herrera-Levano, J. C., Paixão, T., Alvarez, A. B. (2023)	Revista: Applied Sciences Factor de impacto: 2.5 Países: Perú, Brasil	6 800 imágenes extraídas de 6 videos del dataset NITYMED (4 760 entrenamiento; 1 020 validación; 1 020 prueba) Tipo de estudio: Experimental	No indica
A Deep-Learning Approach to Driver Drowsiness Detection	Ahmed, M. I. B., Alabdulkarem, H., Alomair, F., Aldossary, D., Alahmari, M., Alhumaidan, M., Alrassan, S., Rahman, A., Youldash, M., Zaman, G. (2023)	Revista: safety Factor de impacto: 2.1 País: Arabia Saudita	2 900 imágenes etiquetadas en 4 clases (open, closed, yawning, no yawning) Tipo de estudio: Experimental	No indica
Driving fatigue onset and visual attention: An electroencephalography-driven analysis of ocular behavior in a driving simulation task	Giorgi, A., Borghini, G., Colaiuda, F., Menicocci, S., Ronca, V., Vozzi, A., Rossi, D., Aricò, P., Capotorto, R., Sportiello, S., Petrelli, M., Polidori, C., Varga, R., Van Gasteren, M., Babiloni, F., Di Flumeri, G. (2024)	Revista: Behavioral Sciences Factor de impacto: 2.6 Países: Italia, España	19 conductores profesionales (9 furgonetas, 10 camiones; 18 hombres, 1 mujer; edad Tipo de estudio: Experimental	Conducción simulada de 1 hora por participante: 15 min de adaptación + 45 min de conducción monótona a 25 fps (1080p/720p) en ambiente de simulador, realizada en horario vespertino

Real-time driver monitoring system with facial landmark-based eye closure detection and head pose recognition	Kim, D., Park, H., Kim, T., Kim, W., Paik, J. (2023)	Revista: Scientific Reports Factor de impacto: 3.9 País: Corea del Sur	160 secuencias de vídeo infrarrojo Tipo de estudio: Experimental	No indica
Detection of human drowsiness by the vestibulo-ocular reflex compensating for heartbeat-induced head perturbations	Yamanaka, T., Hirata, Y. (2024)	Revista: Scientific Reports Factor de impacto: 3.9 País: Japón	15 participantes (12 hombres, 3 mujeres; 22 ± 1.8 años) Tipo de estudio: Experimental	Sesiones de reposo de 12 min con autoevaluaciones de somnolencia cada 2 min
Real-Time Deep Learning-Based Drowsiness Detection: Leveraging Computer-Vision and Eye-Blink Analyses for Enhanced Road Safety	Safarov, F.; Akhmedov, F.; Abdusalomov, A. B.; Nasimov, R.; Cho, Y. I. (2023)	Revista: Sensors Factor de impacto: 3.4 Países: República de Corea, Uzbekistán	No indica Tipo de estudio: Experimental	No indica
Exploration of Eye Fatigue Detection Features and Algorithm Based on Eye-Tracking Signal	Sun, W., Wang, Y., Hu, B., Wang, Q. (2024)	Revista: Electronics Factor de impacto: 2.6 País: China	19 participantes (y 20 000 muestras de datos) Tipo de estudio: Experimental	Sesiones de cuarenta minutos repartidas en 5 minutos por tarea realizada
Real-time driver drowsiness detection using transformer architectures: a novel deep learning approach	Hassan, O. F., Ibrahim, A. F., Gomaa, A., Makhlouf, M. A., Hafiz, B. (2025)	Revista: Scientific Reports Factor de impacto: 3.9 País: Egipto	178 619 imágenes totales (84 898 del MRL Eye, 66 521 del NTHU-DDD, 27 200 del CEW) Tipo de estudio: Experimental	No indica
A novel approach of drowsiness levels detection using Vis-Net combined with facial emotion	Phan, T.-C., Phan, A.-C. y Nguyen, N.-H.-Q. (2025)	Revista: Systems and Soft Computing Factor de impacto: 3.6 País: Vietnam	12 conductores (6 hombres y 6 mujeres), edades 22–50 años. Tipo de estudio: Experimental	cada sujeto realizó 4 sesiones de conducción de 20 min en distintas condiciones (iluminación diurna/nocturna, con/sin gafas o mascarilla), totalizando 48 sesiones

Tabla 3. Sistematización de las principales características de los estudios seleccionados para la revisión.

En total se seleccionaron 20 artículos, 19 pertenecientes a diversas publicaciones y uno perteneciente a un congreso internacional. Del total de artículos, 20 % pertenecen a la publicación Sensors, 15% a Scientific reports y 10% a Electronics, el resto de las publicaciones aportan un 5% de representación cada una.

Al realizar un análisis de los estudios presentados, se puede determinar la presencia de un sesgo significativo en la representación de la población y las condiciones experimentales que limita a los hallazgos encontrados. Al no contar con metodologías estandarizadas, es difícil analizar eficientemente la información, debido a que las metodologías tienen muestras, duración y condiciones generales de cada uno de los experimentos). Los estudios hacen uso de datasets de imágenes y técnicas de Deep learning que son considerados como técnicas innovadoras. Sin embargo, se considera que se deben utilizar muestras más grandes, estandarizar y detallar mejor los experimentos de somnolencia, realizar validaciones con simuladores o bien con datasets ya existentes, así como clarificar el uso de éstos.

Abordar estos sesgos permitirá construir una base de evidencia más robusta y aplicable para el desarrollo de sistemas efectivos de detección de somnolencia en conductores.

3. Resultados

Basado en el objetivo principal de esta revisión sistemática y en evidencias aportadas por la literatura, se generaron temas analíticos como: Somnolencia del conductor y métodos para detectar la somnolencia en el conductor.

3.1 Somnolencia del conductor

La somnolencia en conductores constituye una de las causas más comunes de accidentes de tráfico a nivel mundial (You et al., 2020). Se describe como un sentimiento donde el individuo se percibe agotado, cansado y con poca energía motivado al desgaste físico por la ejecución de una actividad. Ricci, Chee, Lorandeanu y Berger (2007, citado en Vega-Valero, 2019) describen la somnolencia como la consecuencia de múltiples factores que agotan la energía de un individuo. Las personas que la padecen reportan síntomas de agotamiento físico, dolores en la cabeza, músculos y con disminución de actividad física. Por las razones expuestas, se requiere que se realicen investigaciones que conduzcan a reconocer de forma inteligente y eficiente, la somnolencia en los conductores que son los responsables de su propia vida y la de sus pasajeros incluyendo personas del entorno donde éstos desempeñan su oficio.

3.2 Métodos para detección de somnolencia

Con la finalidad de mejorar la metodología e incrementar la precisión de detección de la somnolencia del conductor, se han desarrollado varios enfoques, presentando a continuación algunos de ellos.

En el marco de integrar y mejorar la detección de la somnolencia en conductores, You et al. (2020) propone una metodología que pretende medir características de precisión, velocidad y robustez que son consideradas elementos claves para la detección de síntomas de estas condiciones. En tal sentido, su propuesta incluye una totalidad de tres módulos para la extracción de:

- Rasgos faciales.
- Regiones oculares.
- Detección de somnolencia.

En el primero de los módulos se realiza un diseño de red neuronal convolucional en cascada profunda que conduce a la detección del rostro y a la vez localiza los puntos clave de los ojos. Seguidamente, se pasa a la construcción del submódulo que realiza el seguimiento facial aumenta la velocidad de algoritmo aplicándose la validación facial lo que mejora la estabilidad de la detección. Con el fin de garantizar la función ordenada de los submódulos, se diseñó un bucle de reconocimiento basado en la máquina de estados finitos, la cual extrae los rasgos faciales del conductor.

En el segundo módulo, se hizo una captura de las regiones de los ojos del conductor utilizando como característica geométrica la cara y los ojos. En el tercer módulo que permitió detectar la somnolencia, se aplicó el método de ajuste de elipse para obtener la forma de las pupilas del conductor. De acuerdo con la relación entre los ejes largo y corto de la elipse, decide el estado de los ojos ya sea abiertos o cerrados. Finalmente, se usó el PERCLOS, que se define calculando el número de ojos cerrados en un período, para determinar si se conduce en estado de somnolencia o no. Los resultados experimentales evidenciaron que la precisión integral de la detección de somnolencia es del 95.87%. La tasa promedio del algoritmo es de 32.29 ms/f en una imagen de 640×480 píxeles. Esta investigación contribuye a mejorar el diseño de otros estudios que tengan como propósito la generación de nuevos sistemas para detectar la somnolencia en los conductores.

Por su parte, Jasim et al. (2022) utilizaron un método económico y no intrusivo con la finalidad de detectar la somnolencia del conductor mediante el monitoreo del rostro y los ojos, colocando una cámara de buena resolución y bajo costo denominada CAM 313. En su estudio concluyeron que el reconocimiento del estado de los ojos es una tecnología muy precisa. Para prevenir accidentes, pueden detectar la somnolencia del conductor de forma temprana. A modo de comparación, descubrieron que el uso de un enfoque híbrido brinda una precisión del 91.18 % y el 97.06 %, mientras que el uso solo de una ANN brinda una precisión del 82.35 % y el 86.76 %, lo que hace que el enfoque híbrido sea superior al algoritmo de ANN. Aunque el método propuesto produjo resultados de gran precisión, aún hay margen para el cambio. Los enfoques conductuales combinados con estrategias fisiológicas pueden proporcionar una ventaja significativa en el futuro.

Siguiendo los métodos que tienen como objetivo detectar la somnolencia del conductor, Chirra et al. (2019) analizaron la función de los ojos como medio de detección. Con este análisis se determinaba si el individuo estaba somnoliento o alerta activando una alarma cuando el estado del ojo indicaba el primer estado. Se utilizó para este objetivo el algoritmo de detección de Viola Jones. En el proceso de desarrollo una red neuronal convolucional profunda aplicada para extraer características en la fase de aprendizaje. Se hizo uso de una capa SoftMax en el clasificador CNN para clasificar al conductor como dormido o no dormido. El sistema propuesto alcanzó una precisión del 96.42 % evidenciándose que identificaba de forma eficaz el estado del conductor emitiendo una alarma cuando el modelo predice un estado de somnolencia. De los resultados anteriores, se afirma que es recomendable en el futuro utilizar el aprendizaje por transferencia para el mejoramiento del rendimiento del sistema.

Para verificar la efectividad de la metodología ET en la detección de somnolencia, Sun et al. (2024) utilizaron múltiples estructuras de red neuronal. El estudio fue realizado utilizando un dispositivo eye tracker diseñado previamente por los autores, con el objetivo de obtener parámetros como el tamaño de la pupila, la duración de parpadeo y la fijación de la vista. Se realizó un análisis ANOVA con el objetivo de interpretar los datos para relacionarlos con los síntomas de somnolencia. Además de los modelos anteriores se desarrollaron otros para verificar qué enfoque funcionaba mejor. Los dos enfoques de entrenamiento fueron: procesado de imágenes y con datos numéricos directamente extraídos del dispositivo eye tracker. Los resultados favorecieron a los modelos de

procesamiento de imágenes siendo el de mejor rendimiento el tipo de red auto encoder con un resultado de precisión de 82.4%. Además de lo anterior se desarrolló una red que combinaba ambos enfoques llamada Auto-Encoder Feature Union que alcanzó una precisión de 87.9%.

Otro método que vale la pena destacar fue el utilizado por Li et al. (2023), el cual se basa en un par de lentes que monitorean de cerca el estado de los ojos. Para el desarrollo de este sistema, se utilizó un armazón al cual se le colocó un tipo de lente especial denominado espejo caliente, con la característica de reflejar luz infrarroja mientras le permite el paso al resto de la luz. En el armazón se encuentran instalados una unidad procesadora de datos, una cámara que adquiere imágenes del ojo y una fuente de luz infrarroja.

Para realizar el reconocimiento del estado del ojo (si este se encuentra abierto o cerrado) primero se entrenó una red neuronal ligera con una estructura de bloques residuales tipo hourglass, a la cual se le introdujeron imágenes provenientes de la cámara ubicada en el armazón de los lentes, estas imágenes pasaron por un proceso de modificación en el cual se agregaron puntos al rededor del ojo conocidos como landmarks. Estos landmarks eran necesarios para permitir el rastreo de los movimientos del párpado mediante cálculos EAR (Eye Aspect Ratio). El método EAR calcula el área que delimitan los puntos agregados a las imágenes de entrenamiento permitiendo determinar datos como el porcentaje de cierre del ojo a partir de umbrales de valores de área. El uso de la red tipo hourglass fue importante debido a que, al capturar imágenes del ojo en ángulo mediante un reflejo, la forma de éste se distorsionaba dando como resultado una imagen difícil de analizar.

Se realizó una comparativa de funcionamiento con un dispositivo previamente existente denominado eyelink, la comparativa se llevó a cabo con dos métodos de detección de somnolencia, el porcentaje de cierre de ojo (PERCLOS) y la frecuencia de parpadeo, el segundo caso en particular muestra resultados similares para ambos dispositivos. Los datos finales indican que el dispositivo es capaz de detectar parpadeos un 93.9% de las ocasiones. El hecho de que la frecuencia de parpadeo haya sido similar en ambos dispositivos, demuestra que la capacidad de captura y procesado no necesariamente debe ser extremadamente alta para permitir la captura de movimientos oculares.

Una investigación que se enfoca en la utilización del eye aspect ratio para monitoreo ocular, es la presentada por Dewi et al. (2022), la cual se vale de la librería Dlib para ubicar coordenadas específicas de áreas de interés en los ojos en forma de landmarks. Una vez ubicadas las coordenadas, se aplica la fórmula del EAR para lograr medir el área de apertura del ojo. Este autor experimentó con cuatro umbrales de EAR para definir el punto en el que un movimiento del ojo es un parpadeo (0.18, 0.20, 0.225 y 0.25). Los cuatro umbrales son analizados en tres bases de datos y se analizan los resultados a partir del área bajo la curva. Los resultados presentados por los escritores citados previamente, muestran que el sistema final cuenta con un 97% de precisión en la detección de parpadeos utilizando un umbral de 0.18. El uso del EAR puede presentar ciertas limitaciones, ya que se trata de una métrica matemática derivada de la geometría del ojo. Esto la hace sensible a factores como el ángulo de captura, la resolución de la imagen o pequeñas imprecisiones en la detección de los landmarks. Por este motivo, establecer umbrales adecuados para distinguir entre ojos abiertos y cerrados es fundamental, aunque la captura de imágenes puede requerir ajuste dependiendo del entorno y del sujeto.

Una investigación realizada por Dziuda et al. (2021), dio como resultado un prototipo de sensor detector de somnolencia, además de una evaluación de métricas de somnolencia que compara el porcentaje de cierre, la frecuencia de parpadeo y la velocidad de cierre de

ojo con el objetivo de verificar qué tan efectivas eran estas métricas, se desarrolló una cabina de pruebas en la cual ocho sujetos debían realizar un recorrido. El sensor de somnolencia utilizado consta de una cámara Ximea MQ013RG-E2 a la que se le agrega un objetivo Tamron de distancia focal fija que permite un buen grado de captura de luz infrarroja. Lo anterior es utilizado en conjunto con un anillo de leds infrarrojos para no perder imagen del sujeto en entornos de oscuridad.

Toda la cámara y el anillo de iluminación están integrados en una carcasa de aluminio anodizado, diseñada a medida para fijarse al tablero del simulador con un soporte articulado de tres grados de libertad. Para la detección de rostro se utilizó la librería FaceSDK y Template Matching con los rostros de cada uno con los sujetos de prueba.

Para la obtención de datos los ocho sujetos de prueba, se realizaron recorridos en el simulador con duración entre 40 y 48 minutos y se analizaban los datos obtenidos por métrica. La conclusión a la que llegó el estudio, fue que la velocidad de cierre de ojo es el parámetro más fiable, siendo capaz de detectar estados generales de somnolencia además de la diferencia en la severidad del estado conforme pasa el tiempo. La segunda mejor métrica fue el porcentaje de cierre, que se considera un indicador fiable del aumento de la somnolencia con el paso del tiempo. La frecuencia de parpadeo como indicador no mostró resultados particularmente efectivos como métrica de detección de somnolencia. La anterior información es vital para el desarrollo de cualquier sistema de detección de somnolencia debido a que indica cuáles son las métricas a las que se les debe dar más importancia en el análisis ocular.

Un sistema que vale la pena destacar es el desarrollado por Beles et al. (2024), el cual combina el monitoreo de señales bioeléctricas con el seguimiento ocular. En este caso se emplea electrooculografía junto con una red entrenada bajo una arquitectura de perceptrón multicapa para clasificar el estado del párpado. Para la parte de señales bioeléctricas se utilizan electrodos que se colocan alrededor del ojo. Las señales provenientes de estos electrodos se filtran y acondicionan para permitir una correcta interpretación de la señal, luego se buscan picos, los cuales representan el movimiento de los ojos y se utiliza lógica difusa para permitir clasificaciones de comportamiento.

Para el reconocimiento del estado de los ojos, se utiliza una red neuronal alimentada con imágenes de ojos tanto abiertos como cerrados. Se utilizó una arquitectura de perceptrón multicapa y un conjunto de entrenamiento de 200 imágenes.

Los resultados de ambos monitoreos alimentan una lógica difusa tipo Mamdani que extrae el nivel de alerta según la frecuencia/distribución de parpadeo mediante electrooculografía y la clasificación binaria de los ojos mediante cálculo de EAR. Para la parte bioeléctrica, el sistema mostró un grado alto de repetibilidad y consistencia para detectar parpadeos y movimientos oculares característicos del estado de somnolencia, mientras que para la red neuronal que detecta el estado del ojo se tiene una precisión del 90%. La lógica difusa es otra forma válida para el desarrollo de este tipo de sistemas, si bien es algo más restrictiva con sus criterios de evaluación, esto mismo la vuelve más fácil de controlar para desempeñar sus tareas de forma efectiva.

La investigación de Zhuang et al. (2020) presenta otro dispositivo de detección de somnolencia que funciona a partir de una red neuronal que detecta el porcentaje de apertura del ojo. Esto es posible utilizando la librería Dlib que ubica landmarks particulares en el rostro. El dispositivo emplea una red tipo U-Net ligera o de segmentación a nivel de píxel, para extraer mapas de características de pupila e iris con

el objetivo de que la red se enfoque en las regiones importantes del ojo. Se tiene un segundo módulo de decisión el cual determina el porcentaje de cierre. Las pruebas de precisión se llevaron a cabo utilizando un conjunto de datos obtenido del repositorio NTHU-DDD (National Tsing Hua University Drowsy Driver Detection Video Dataset). Como resultado, el método exhibió una precisión del 96.72%.

La investigación de Ahmed et al. (2023) muestra el entrenamiento de dos redes neuronales que detectan el estado de tanto los ojos como la boca a partir de un dataset preexistente. Una de las redes cuenta con una estructura ligera personalizada, compuesta por capas Conv2D, MaxPooling2D, Flatten y Dropout sin precarga de pesos y con una función de activación softmax para clasificación. La otra red está basada en la arquitectura VGG16 que consta de trece capas convolucionales y tres capas densas o completamente conectadas. A la red de arquitectura VGG16 se le precargaron pesos provenientes del dataset ImageNet a partir del método de transfer learning.

Las métricas principales para la validación de los resultados fueron precisión, recall y f1-score. En el caso del modelo que utiliza una estructura ligera personalizada se obtuvieron métricas casi perfectas (de 99%) para todas las salidas. El modelo de VGG16 sin embargo tuvo resultados precarios de al menos una de las métricas en cada salida. Cabe destacar que el modelo de estructura VGG16 se entrenó utilizando los pesos precargados de ImageNet por lo cual es posible que estos pesos afectaran el rendimiento de la red, sería conveniente revisar el rendimiento de VGG16 cuando no se utiliza transfer learning.

Otra investigación que presenta el uso de metodología de seguimiento ocular en conjunto con señales bioeléctricas es la realizada por Giorgi et al. (2024) que se basa en caracterizar los comportamientos de los ojos cuando un conductor entra en estado de somnolencia. Para lograr lo anterior se realizaron pruebas en un total de 20 conductores expertos, quienes manejaron en un simulador dos tipos de secciones, una más dinámica y otra más monótona. En esta investigación el papel del seguimiento ocular fue monitorear el desplazamiento de atención visual en conjunto con resultados de monitoreo electroencefalográfico para determinar cómo varían los comportamientos en un estado de somnolencia. La investigación demostró que existe una tendencia en los conductores en estado de somnolencia de enfocar su vista en entornos con menor nivel de información en lugar de zonas más importantes, lo cual favorece las probabilidades de accidentes viales. El descubrimiento de estas tendencias presentes en el comportamiento de los conductores da una mayor gama de posibilidades para el desarrollo de nuevos y más eficientes sistemas de seguimiento ocular que permitan la detección de síntomas de somnolencia.

Yamanaka y Hirata (2024) presentan una investigación con una metodología de detección de somnolencia algo menos conocida en comparación con PERCLOS o la duración de parpadeo. El enfoque principal es el monitoreo del reflejo vestíbulo-ocular, que permite que la imagen captada por el ojo se mantenga visualmente estable al realizar movimientos con la cabeza. Las investigaciones previas mencionan que la efectividad de este reflejo se reduce al encontrarse en estados de somnolencia por lo que su monitoreo podría ser empleado para detectar esta condición. Este monitoreo es posible debido a que se descubrió que los latidos del corazón generan pequeños movimientos que son capaces de activar este reflejo, haciendo que la metodología se vuelva más factible. Para comprobar lo anterior se utilizaron los parámetros de ganancia y variabilidad.

La ganancia determina si la velocidad de movimiento del ojo concuerda con la velocidad del movimiento de la cabeza. Una velocidad 100% igual implica una buena

capacidad de reflejo vestibulo-ocular, y ésta se va reduciendo conforme aumenta el grado de somnolencia. Los escritores entrenaron una SVM (Support Vector Machine) para reconocer estados de somnolencia a partir de los parámetros de reflejo vestibulo-ocular. Los resultados muestran una precisión en la detección de somnolencia de 80% para movimientos horizontales y 71.2% para movimientos verticales.

Otro sistema destacable es el desarrollado por Kim et al. (2023) el cual utiliza un modelo de red neuronal creado a partir de la estructura YOLOv7 que está basado en dos módulos que funcionan a partir de la detección facial. El primero de estos módulos es un detector de somnolencia que realiza la inferencia en función de la posición de las landmarks presentes en los ojos. El segundo módulo es un detector de atención del conductor que monitorea la posición de la cabeza para verificar que la visión siempre esté enfocada en el camino. Para la creación de este sistema, el laboratorio CANLAB desarrolló una cámara infrarroja personalizada que funciona como dispositivo de adquisición y procesamiento de imágenes. Esta cámara se encuentra ubicada en la parte trasera del volante del vehículo con el objetivo de reducir la distancia con el rostro del conductor, de modo que las imágenes no pierdan un grado alto de calidad. Esta estrategia es muy efectiva, debido a que los autores reportan un grado perfecto de precisión (100 %) en el modelo de detección de rostro independientemente del grado de iluminación.

Un elemento para tomar en cuenta en el desarrollo del dispositivo es el uso de YOLOv7 debido a que esta arquitectura se relaciona con modelos pesados que no son tan sencillos de ejecutar en sistemas embebidos, prueba de esto es que utilizando una jetson Xavier, que es una tarjeta de desarrollo particularmente potente y diseñada para trabajar con modelos de IA, lograron un rendimiento de 10fps que en algunos casos se considera apenas aceptable para aplicaciones de video en tiempo real. Sin embargo, el sistema final es capaz de funcionar a una tasa de 30 fps, esto se debe a la cámara especialmente diseñada para el sistema por el laboratorio CANLAB.

Siguiendo con el uso de estructuras con un alto consumo de recursos para reconocimiento facial, Hassan et al. (2025) utiliza la arquitectura transformer con el objetivo de detectar el estado en el que se encuentran los ojos (abierto o cerrado). Se utilizaron dos arquitecturas tipo transformer, Vit y swim. Con el objetivo de validar el uso de las arquitecturas en el proceso de detección de somnolencia, se realizó una comparación con redes convolucionales que utilizaban transfer learning. Para la evaluación se utilizó el dataset MLR en todos los entrenamientos. Ambas redes transformer presentaron una precisión del 99%, dando el mejor resultado de las estructuras de red utilizadas en la comparación.

Otro uso de la arquitectura Vision transformer es el presentado por Phan et al. (2025) en donde utilizan un dataset original para entrenar múltiples modelos de detección de somnolencia. Al igual que en el artículo presentado por Hassan et al. (2025), se utiliza la arquitectura vision transformer además de múltiples redes CNN como punto de comparación. En lugar de realizar la detección y segmentación de las partes importantes del rostro, ya sean los ojos o boca, el modelo es entrenado utilizando el rostro al completo, de esta forma, en lugar de utilizar porcentajes o velocidad de cierre se utilizan cinco niveles que describen el estado del conductor: Alerta total, Leve somnolencia, somnolencia moderada, somnolencia severa y estado de sueño o pérdida completa de conciencia. El modelo vision transformer alcanzó una precisión al menos de 98% para todos los niveles, logrando un algoritmo bastante efectivo para realizar la detección de estados de somnolencia.

El avance de los modelos de reconocimiento y detección facial ha generado múltiples herramientas que pueden ser muy útiles en la detección de síntomas de somnolencia, un buen ejemplo es el framework mediapipe que permite realizar una gran variedad de tareas

referentes al reconocimiento facial que Safarov et al. (2023) aprovechan para el desarrollo de un algoritmo con la capacidad de detectar síntomas de somnolencia utilizando como indicadores la velocidad de cierre de ojos, la frecuencia de cierre, los bostezos y el cambio de posición de la cabeza. La detección de cada uno de estos síntomas trabaja en función a los umbrales que establece el autor, para determinar el porcentaje de cierre de los ojos utiliza EAR, para la detección de bostezos MAR (Mouth Aspect Ratio) el cual tiene un funcionamiento similar al EAR pero aplicado en la boca, en el caso de la inclinación de la cabeza se mide el desplazamiento que han tenido la frente y la barbilla con respecto al frame anterior. Como métricas de precisión se obtienen: 95.8 % de en detección de ojos cerrados, 97 % en detección de ojos abiertos, 84 % en detección de bostezos y 98 % y 100 % en inclinación de cabeza a derecha e izquierda, respectivamente. El desarrollo de este de este algoritmo permite confirmar la viabilidad del uso de frameworks como mediapipe con el objetivo de obtener herramientas que permitan detectar los síntomas de somnolencia.

Un sistema de detección de somnolencia particularmente completo es el presentado por Florez et al. (2023), quienes plantean un sistema embebido que detecta síntomas de somnolencia a partir de métricas estrictas de porcentaje de cierre de ojo y conteo de bostezos, utilizan la librería mediapipe con el objetivo de segmentar las regiones de interés que en este caso son los ojos (ambos en una sola salida) y la boca. La arquitectura utilizada es una personalizada que los autores denominan DD-AI, que cuenta con un total de ocho capas. Además de lo anterior, se utilizaron arquitecturas VGG, ResNet e Inception. El sistema embebido utilizado es una Jetson Nano debido a sus capacidades para trabajar con modelos de inteligencia artificial. Los resultados de entrenamiento de todos los modelos empleados muestran métricas de precisión para la detección de casos de somnolencia del 98% para todos los modelos empleados, incluyendo la estructura DD-AI. La investigación anterior demuestra que las redes ligeras pueden realizar un buen trabajo en la detección de estados de somnolencia.

Finalmente, Ablahd et al. (2024) diseñaron un sistema especial inteligente, fiable y preciso, utilizando el lenguaje Python 3.6 para Windows, para crear un sistema de alerta con la finalidad de detectar la somnolencia de los conductores. Este sistema se consideró primordial para la reducción de accidentes de tráfico. El sistema implementaba un detector en tiempo real que controlaba los estados de los conductores durante la conducción. La metodología usada utilizó cámaras inteligentes de 16 megapíxeles para garantizar que las fotografías capturadas tuvieran una alta calidad. Se procedió a recopilar el conjunto de datos del conductor en diferentes estados incluyendo los de alerta y somnolencia.

El conjunto de datos recopilados se procesó extrayendo todas las características relevantes, como el movimiento de la cabeza, los bostezos y el cierre de los ojos, que se utilizaron para identificar la somnolencia del conductor. Las bibliotecas de Python, como TensorFlow, OpenCV, Keras y Pygame, se utilizan para extraer todas las características anteriores. El algoritmo de Viola-Jones se utiliza para detectar y extraer la región ocular de la imagen de la cara en el sistema propuesto. Se usó un algoritmo de máquina de vectores de soporte (SVM) para clasificar entre conductores somnolientos y no somnolientos. El sistema de prueba se evaluó en el mundo real para garantizar que sea confiable y robusto, mostrando un alto rendimiento y una precisión de aproximadamente el 99.1%.

4. Discusión

La presente revisión tuvo como propósito analizar la efectividad del método ET para la obtención y análisis de perfiles de somnolencia en conductores. Desde la perspectiva

de los autores revisados, You et al. (2020) y Ricci, Chee, Lorandeanu y Berger (2007, citado en Vega-Valero, 2019) consideran que la somnolencia se manifiesta en los conductores como el deterioro de sus habilidades debido a la ejecución de su tarea. En tal sentido, valoran que se realicen investigaciones que lleven a identificar metodologías inteligentes para reconocer la somnolencia en los conductores y de esta manera salvaguardar sus vidas y la de sus pasajeros.

You et al. (2020) propusieron una metodología que se enfatizaba en la precisión, la velocidad y la robustez dividida en módulos donde se incluía el método ET, la cual demostró gran efectividad. En este mismo objetivo, Jasim et al. (2022) basaron su estudio en un método económico que evitaba ser intrusivo y pretendía detectar la somnolencia del conductor mediante el monitoreo del rostro y los ojos, colocando una cámara de buena resolución (CAM 313). El estudio demostró precisión respecto al objetivo propuesto y recomendó a futuro utilizar enfoques conductuales combinados.

En este mismo orden de ideas, siguiendo los métodos que tienen como objetivo detectar la somnolencia en conductores, Chirra et al. (2019) utilizaron el algoritmo de detección de Viola Jones y desarrollaron una red neuronal convolucional profunda apilada para extraer características en la fase de aprendizaje. Su estudio alcanzó una precisión de 96.42 % demostrando eficacia para detectar signos de somnolencia en conductores. Por su parte, Ablahd et al. (2024) diseñaron un sistema de alerta que se destacó por el elevado rendimiento y precisión ubicada en 99.1% en la detección de somnolencia en conductores.

Los trabajos presentados por Beles et al. (2024), Kim et al. (2023), Zhuang et al. (2020) y Florez et al. (2023) demuestran que es posible desarrollar sistemas que funcionen en tiempo real con una tasa de frames lo suficientemente estable como para permitir el monitoreo del proceso de parpadeo completo, además de brindar estrategias para que estos sistemas funcionen aun con una cantidad baja de iluminación.

Tanto Safarov et al. (2023) como Florez et al. (2023) demuestran las ventajas de utilizar modelos o frameworks preexistentes con el fin de mejorar y facilitar los procesos de detección y segmentación de zonas faciales de interés para el reconocimiento de síntomas de somnolencia.

Así mismo, vale la pena destacar los esfuerzos de múltiples estudios que se dedicaron a la validación de metodologías de detección de somnolencia. Sun et al. (2024) validaron múltiples parámetros biométricos para la detección de cambios en zonas de interés, mientras que Dewi et al. (2022) se dedicaron a buscar umbrales de “eye aspect ratio” que se pudieran aplicar de forma general. Dziuda et al. (2021) puso a prueba los métodos PERCLOS, velocidad y frecuencia de parpadeo para determinar si eran marcadores de somnolencia efectivos. Por último, Yamanaka e Hirata (2024) se centraron en el monitoreo del reflejo vestibulo-ocular con el fundamento de que el propio latido del corazón genera pequeños movimientos que lo activan.

Las investigaciones de Hassan et al. (2025), Phan et al. (2025) y Kim et al. (2023) se enfocaron en el desarrollo de redes a partir de arquitecturas que dan como resultado modelos más precisos, pero también algo más demandantes a nivel de hardware, siendo en el caso de los primeros dos artículos la arquitectura transformer y en el tercero la arquitectura YOLOv7. En los primeros dos artículos las métricas de precisión fueron muy favorables, aunque no se llegó a comprobar el rendimiento en sistemas embebidos, para el tercer caso se diseñó un equipo especializado que recolectaba imágenes y las procesaba a la vez dando resultados favorables de precisión y una buena tasa de frames.

Ahmed et al. (2023) desarrollaron una estructura de red neuronal propia con un menor gasto computacional, la cual fue capaz de igualar en precisión a estructuras de red preestablecidas a pesar de que éstas utilizaban transfer learning.

Li et al. (2023) presentaron un enfoque en el cual la recolección de imágenes ocurría extremadamente cerca de las zonas de interés. Utilizando una estructura de gafas, fueron capaces de obtener un sistema con un grado aceptable de precisión que podía obtener imágenes detalladas de los ojos sin tener que lidiar con los problemas que conlleva la distancia entre la cámara y el conductor evitando problemas de ruido.

5. Conclusiones

Los hallazgos demostraron que el método ET para la obtención y análisis de perfiles de somnolencia en conductores, muestra una gran efectividad visible en las evidencias científicas analizadas, lo que lleva a los encargados de diseñar mejoras en la metodología de estos sistemas a seguir profundizando en las investigaciones para la detección de la somnolencia en los conductores, ya que se ha convertido una problemática que afecta las vidas de miles de personas a lo largo del mundo. El conjunto de trabajos analizados brinda un panorama claro del uso y avance de esta tecnología en la actualidad, permitiendo identificar cuáles son las áreas de mejora en un área de estudio que podría salvar innumerables vidas. La presente investigación ofrece un panorama con respecto al estado más actual de la tecnología ET en el ámbito de la detección de somnolencia, demostrado en el 65% de los trabajos incluidos que datan de 2023 a 2025. Esto en conjunto con el criterio de selección basado en fuentes de acceso abierto pone de manifiesto que la investigación no solo está al día con los avances metodológicos más recientes, sino que además ofrece una síntesis reproducible y utilizable inmediatamente por cualquier lector.

Uno de los motivos para la realización de la investigación fue el de revisar antecedentes recientes del uso de la tecnología ET en la detección de somnolencia, con el fin de conocer su estado actual y las áreas de mejora existentes en las implementaciones de estas alternativas. Lo anterior se aplicará en el diseño de un sistema de detección de somnolencia que aplicará el método ET tomando en cuenta las variables utilizadas en el monitoreo de esta condición.

6. Referencias

- AAA Foundation for Traffic Safety. (2024). *Drowsy driving in fatal crashes, United States, 2017–2021* (Research Brief, marzo 2024). <https://aaafoundation.org/wp-content/uploads/2024/03/202304-AAAFTS-Drowsy-Driving-Countermeasures.pdf>
- Ablahd, A. Z., Aloraibi, A. Q., y Dawwod, S. A. (2024). Driver drowsiness detection. *Scalable Computing: Practice and Experience*, 25(5). <https://doi.org/10.12694/scpe.v25i5.3046>
- Ahmed, M. I. B., Alabdulkarem, H., Alomair, F., Aldossary, D., Alahmari, M., Alhumaidan, M., Alrassan, S., Rahman, A., Youldash, M., y Zaman, G. (2023). A deep-learning approach to driver drowsiness detection. *Safety*, 9(3), 65. <https://doi.org/10.3390/safety9030065>
- Beles, H., Vesselenyi, T., Rus, A., Mitran, T., Scurt, F. B., y Tolea, B. A. (2024). Driver drowsiness multi-method detection for vehicles with autonomous driving functions. *Sensors*, 24(5), 1541. <https://doi.org/10.3390/s24051541>
- Chirra, V., Reddy, U. S., y KishoreKolli, V. (2019). Deep CNN: A machine learning approach for driver drowsiness detection based on eye state. *Revue d'Intelligence Artificielle*, 33, 461–466. <https://doi.org/10.18280/ria.330609>
- Dewi, C., Chen, R.-C., Chang, C.-W., Wu, S.-H., Jiang, X., y Yu, H. (2022). Eye aspect ratio for real-time drowsiness detection to improve driver safety. *Electronics*, 11(19), 3183. <https://doi.org/10.3390/electronics11193183>
- Dziuda, Ł., Baran, P., Zieliński, P., Murawski, K., Dziwosz, M., Krej, M., Piotrowski, M., Stablewski, R., Wojdas, A., Strus, W., Gasiul, H., Kosobudzki, M., y Bortkiewicz, A. (2021). Evaluation of a fatigue detector using eye closure-associated indicators acquired from truck drivers in a simulator study. *Sensors*, 21(19), 6449. <https://doi.org/10.3390/s21196449>
- Florez, R., Palomino-Quispe, F., Coaquira-Castillo, R. J., Herrera-Levano, J. C., Paixão, T., y Alvarez, A. B. (2023). A CNN-based approach for driver drowsiness detection by real-time eye state identification. *Applied Sciences*, 13(13), 7849. <https://doi.org/10.3390/app13137849>
- Giorgi, A., Borghini, G., Colaiuda, F., Menicocci, S., Ronca, V., Vozzi, A., Rossi, D., Aricò, P., Capotorto, R., Sportiello, S., Petrelli, M., Polidori, C., Varga, R., Van Gasteren, M., Babiloni, F., y Di Flumeri, G. (2024). Driving fatigue onset and visual attention: An electroencephalography-driven analysis of ocular behavior in a driving simulation task. *Behavioral Sciences*, 14(11), 1090. <https://doi.org/10.3390/bs14111090>
- Hassan, O. F., Ibrahim, A. F., Gomaa, A., Makhlof, M. A., y Hafiz, B. (2025). Real-time driver drowsiness detection using transformer architectures: A novel deep learning approach. *Scientific Reports*, 15, 17493. <https://doi.org/10.1038/s41598-025-02111-x>
- Instituto Nacional de Estadística y Geografía (INEGI). (s. f.). *Accidentes de tránsito*. Recuperado el 26 de octubre de 2025, de <https://www.inegi.org.mx/temas/accidentes/>
- Jasim, S. S., Abdul Hassan, A. K., y Turner, S. (2022). Driver drowsiness detection using Gray Wolf optimizer based on face and eye tracking. *ARO – The Scientific Journal of Koya University*, 10(1), 49–56. <https://doi.org/10.14500/aro.10928>
- Kim, D., Park, H., Kim, T., Kim, W., y Paik, J. (2023). Real time driver monitoring system with facial landmark based eye closure detection and head pose recognition. *Scientific Reports*, 13, 18264. <https://doi.org/10.1038/s41598-023-44955-1>
- Satapathy, S. K., Mori, H., Naik, K., y Rajput, N. S. (2023). Automated drowsiness detection for driver safety: A deep learning-based approach. En *2023 International Conference on Computational Intelligence and Sustainable Engineering Solutions (CISES)* (pp. 774–779). <https://doi.org/10.1109/CISES58720.2023.10183506>
- Li, Y., Zhang, S., Zhu, G., Huang, Z., Wang, R., Duan, X., y Wang, Z. (2023). A CNN based wearable system for driver drowsiness detection. *Sensors*, 23(7), 3475. <https://doi.org/10.3390/s23073475>
- Organización Mundial de la Salud. (2023). *Traumatismos causados por el tránsito*. <https://www.who.int/es/news-room/fact-sheets/detail/road-traffic-injuries>
- Phan, T.-C., Phan, A.-C., y Nguyen, N.-H.-Q. (2025). A novel approach of drowsiness levels detection using Vis Net combined with facial emotion. *Systems and Soft Computing*, 7, 200288. <https://doi.org/10.1016/j.sasc.2025.200288>
- Safarov, F., Akhmedov, F., Abdusalomov, A. B., Nasimov, R., y Cho, Y. I. (2023). Real-time deep learning-based drowsiness detection: Leveraging computer vision and eye blink analyses for enhanced road safety. *Sensors*, 23(14), 6459. <https://doi.org/10.3390/s23146459>
- Sun, W., Wang, Y., Hu, B., y Wang, Q. (2024). Exploration of eye fatigue detection features and algorithm based on eye-tracking signal. *Electronics*, 13(10), 1798. <https://doi.org/10.3390/electronics13101798>

- Vega-Valero, C. Z. (2019). Una propuesta de adaptación del cuestionario de síntomas de fatiga laboral. *Revista de Psicología y Ciencias del Comportamiento de la Unidad Académica de Ciencias Jurídicas y Sociales*, 10(1), 74–86. <https://doi.org/10.29059/rpcc.20190602-82>
- Yamanaka, T., y Hirata, Y. (2024). Detection of human drowsiness by the vestibulo-ocular reflex compensating for heartbeat-induced head perturbations. *Scientific Reports*, 14, 23737. <https://doi.org/10.1038/s41598-024-74202-0>
- You, F., Gong, Y. B., Li, X. L., y Wang, H. W. (2020). R2DS: A novel hierarchical framework for driver fatigue detection in mountain freeway. *Mathematical Biosciences and Engineering*, 17(4), 3356–3381. <https://doi.org/10.3934/mbe.2020190>
- Zhuang, Q., Zhang, K., Wang, J., y Chen, Q. (2020). Driver fatigue detection method based on eye states with pupil and iris segmentation. *IEEE Access*, 8, 173440–173449. <https://doi.org/10.1109/ACCESS.2020.3025818>



Esta obra está bajo una licencia de Creative Commons
Reconocimiento-NoComercial-CompartirIgual 2.5 México.