

## REVISIÓN SISTEMÁTICA

### Detection of diabetic retinopathy using artificial intelligence: an exploratory systematic review

### Detección de retinopatía diabética utilizando inteligencia artificial: una revisión sistemática exploratoria

Richard Injante<sup>1</sup>  , Marck Julca<sup>1</sup>  

<sup>1</sup>Universidad Nacional de San Martín, Facultad de Ingeniería de Sistemas e Informática. Tarapoto, Perú.

Citar como: Injante R, Julca M. Detection of diabetic retinopathy using artificial intelligence: an exploratory systematic review. LatIA. 2024; 2:112. <https://doi.org/10.62486/latia2024112>

Recibido: 21-02-2024

Revisado: 08-05-2024

Aceptado: 04-09-2024

Publicado: 05-09-2024

Editor: Prof. Dr. Javier González Argote 

Autor para la correspondencia: Richard Injante 

#### ABSTRACT

Diabetic retinopathy is a disease that can lead to vision loss and blindness in people with diabetes, so its early detection is important to prevent ocular complications. The aim of this study was to analyze the usefulness of artificial intelligence in the detection of diabetic retinopathy. For this purpose, an exploratory systematic review was performed, collecting 77 empirical articles from the Scopus, IEEE, ACM, SciELO and NIH databases. The results indicate that the most commonly used factors for the detection of diabetic retinopathy include changes in retinal vascularization, macular edema and microaneurysms. Among the most commonly applied algorithms for early detection are ResNet 101, CNN and IDx-DR. In addition, some artificial intelligence models are reported to have an accuracy ranging from 90 % to 95 %, although models with accuracies below 80 % have also been identified. It is concluded that artificial intelligence, and in particular deep learning, has been shown to be effective in the early detection of diabetic retinopathy, facilitating timely treatment and improving clinical outcomes. However, ethical and legal concerns arise, such as privacy and security of patient data, liability in case of diagnostic errors, algorithmic bias, informed consent, and transparency in the use of artificial intelligence.

**Keywords:** Deep Learning; CNN; Resnet 101; Blindness; Macular Edema.

#### RESUMEN

La retinopatía diabética es una enfermedad que puede llevar a la pérdida de visión y ceguera en personas con diabetes, por lo que su detección temprana es importante para prevenir complicaciones oculares. El objetivo de este estudio fue analizar la utilidad de la inteligencia artificial en la detección de la retinopatía diabética. Para ello, se realizó una revisión sistemática exploratoria, recopilando 77 artículos empíricos de las bases de datos Scopus, IEEE, ACM, SciELO y NIH. Los resultados indican que los factores más utilizados para la detección de retinopatía diabética incluyen cambios en la vascularización de la retina, edema macular y microaneurismas. Entre los algoritmos más aplicados para la detección temprana se encuentran ResNet 101, CNN e IDx-DR. Además, se reporta que algunos modelos de inteligencia artificial presentan una precisión que varía entre el 90 % y el 95 %, aunque también se han identificado modelos con precisiones inferiores al 80 %. Se concluye que la inteligencia artificial, y en particular el aprendizaje profundo, ha demostrado ser efectiva en la detección temprana de retinopatía diabética, facilitando un tratamiento oportuno y mejorando los resultados clínicos. Sin embargo, surgen preocupaciones éticas y legales, tales como la privacidad y seguridad de los datos del paciente, la responsabilidad en caso de errores de diagnóstico, el sesgo algorítmico, el consentimiento informado y la transparencia en el uso de la inteligencia artificial.

**Palabras clave:** Aprendizaje Profundo; CNN; Resnet 101; Ceguera; Edema Macular.

## INTRODUCCIÓN

Según Cleland CR et al.<sup>(1)</sup> la Retinopatía Diabética (RD) es una afección del ojo que causa pérdida de visión y ceguera en personas con diabetes, ya que afecta los vasos sanguíneos de la retina. Por lo tanto, detectar la RD en sus primeras etapas es vital pues el tratamiento oportuno puede prevenir complicaciones oculares, destacándose la importancia de la detección rápida en pacientes con diabetes.

Una de las principales problemáticas es la necesidad de un diagnóstico exacto de la RD para mitigar su impacto y reducir la dependencia de recursos humanos. La Inteligencia Artificial (IA) ofrece avances en este campo, mejorando el reconocimiento de patrones y diagnósticos precisos.<sup>(2)</sup> Sin embargo, la accesibilidad y los costos de la IA en países de bajos y medianos ingresos siguen siendo inciertos, al igual que las aprobaciones regulatorias necesarias.<sup>(1)</sup> Además, la falta de recursos especializados para el diagnóstico temprano evidencia la necesidad de soluciones precisas y monitoreo en tiempo real que la IA puede proporcionar.<sup>(3)</sup>

Implementar IA para este propósito enfrenta limitaciones, incluyendo la necesidad de recursos extensivos, problemas de flujo de trabajo, y cuestiones de integración tecnológica y privacidad.<sup>(4)</sup> Los dispositivos móviles presentan problemas de calidad de imagen en comparación con cámaras retinianas no portables, y los algoritmos de IA deben adaptarse a iniciativas nacionales de detección de RD.<sup>(5)</sup> Mejorar la interpretación de datos y superar la falta de datos de entrenamiento son críticos, especialmente en áreas rurales y países en desarrollo.<sup>(6,7)</sup> Evaluar los sesgos en los algoritmos de IA es esencial para garantizar representatividad y aplicabilidad.<sup>(8)</sup> Además, la evolución tecnológica requiere actualizaciones constantes en los programas de detección de RD.<sup>(9)</sup> La falta de estándares y la variabilidad demográfica en estudios de IA destacan la necesidad de evaluaciones comparativas y consideraciones legales y éticas.<sup>(10)</sup> Aunque la IA tiene el potencial de mejorar significativamente el diagnóstico y tratamiento de la RD, enfrenta barreras en términos de accesibilidad, costos, calidad de datos, y evaluación de sesgos y estándares.<sup>(11,12,4)</sup>

Los estudios de revisión sistemática sobre la detección de la RD han demostrado cómo la IA ha revolucionado el diagnóstico de esta y otras enfermedades retinianas.<sup>(2)</sup> destacan que la capacidad de la IA para reconocer patrones y compararlos con estándares ha impulsado la detección temprana y el tratamiento oportuno, promoviendo la eficiencia y reduciendo la carga de la enfermedad. Además, la investigación de Cleland CR et al.<sup>(1)</sup> muestra que la IA en la detección de RD presenta altas sensibilidades y especificidades; no obstante, se requiere más investigación sobre aprobaciones regulatorias y mejoras en resultados de salud antes de su implementación a gran escala.

En este marco, el aprendizaje profundo, técnica de IA, permite la detección temprana y precisa de la RD, facilitando tratamientos personalizados y monitoreo en tiempo real, mejorando así la calidad de vida de los pacientes.<sup>(3)</sup> A pesar de su eficacia, Grzybowski A et al.<sup>(4)</sup> señalaron que la implementación de la IA se limita a la integración en sistemas de salud y cuestiones éticas y económicas. Grauslund J.<sup>(5)</sup> también menciona que, aunque la IA muestra alta sensibilidad, su implementación clínica es limitada debido a obstáculos legales y técnicos.

Los avances en IA, específicamente con algoritmos de aprendizaje profundo y el modelo Inception-v3, demostraron alta eficacia en el diagnóstico de enfermedades oculares, comparables a los expertos humanos con menos datos de entrenamiento.<sup>(6,7)</sup> enfatizan que la IA es fundamental para la detección temprana y clasificación de la RD, abordando áreas futuras de investigación en oftalmología. Sin embargo, existen preocupaciones sobre sesgos y falta de representatividad en los estudios, así como la necesidad de estudios económicos para respaldar su implementación.<sup>(8)</sup> Por lo tanto, aunque la IA ha mejorado la detección temprana y efectiva de la RD, se requiere más investigaciones para superar los barreras actuales y garantizar su eficacia y seguridad en la práctica clínica.<sup>(10)</sup>

El objetivo del presente estudio fue analizar la detección de la RD mediante IA, identificando los factores y variables considerados por los modelos, los algoritmos más utilizados, y la precisión de estos algoritmos. Se pretende examinar las limitaciones técnicas en la detección y los desafíos éticos y legales asociados con su implementación.

## MÉTODO

El presente estudio se basó en una revisión sistemática exploratoria, cuyo objetivo principal es analizar y sintetizar la detección de RD utilizando IA. Este tipo de revisión permite obtener una comprensión completa y rigurosa del estado actual del conocimiento, identificando, evaluando y sintetizando críticamente los resultados de estudios previos. La revisión sistemática es fundamental para identificar brechas en el conocimiento y establecer una base sólida para futuras investigaciones y decisiones informadas.

### Preguntas de investigación

Para responder el objetivo propuesto, se trazaron las siguientes preguntas de investigación:

P1: ¿Cuáles son los factores o variables considerados por los modelos en la detección de RD?

P2: ¿Cuáles son los algoritmos más efectivos de detección temprana de la RD utilizando IA?

### 3 Injante R, et al

P3: ¿Cuál es la precisión de los modelos de IA en la detección de RD?

P4: ¿Qué limitaciones técnicas o de implementación enfrentan los sistemas de IA en la detección de la RD?

P5: ¿Qué desafíos éticos y legales plantea el uso de algoritmos de IA en el diagnóstico y tratamiento de la RD?

#### Estrategia de búsqueda

Se utilizó el término clave “diabetic retinopathy” traducido al español como “retinopatía diabética”. Además, se emplearon conectores AND y OR para introducir términos relacionados como “artificial intelligence”. Se seleccionaron las bases de datos Scopus, ACM, SciELO y NIH debido a su amplia cobertura internacional y regional, así como por la facilidad para aplicar filtros de búsqueda avanzada y garantizar la calidad académica de las contribuciones.

Se implementó un proceso de selección en cinco fases:

1. Primera clasificación: consistió en aplicar las cadenas de búsqueda mediante las herramientas avanzadas de cada base de datos, empleándose los campos de título principalmente.
2. Segunda clasificación: se aplicaron los filtros teniendo en consideración los criterios de inclusión y exclusión aplicables manualmente como la cobertura de los años, idioma y tipo de documento.
3. Tercera clasificación: se importaron los metadatos y fueron organizados en Excel, allí se depuraron los duplicados teniendo como referencia la base de datos de Scopus.
4. Cuarta clasificación: filtrado de artículos enfocados en la IA para la detección de RD mediante la lectura del título y resumen.
5. Quinta clasificación, se realizó una selección final de artículos descargables y relevantes para el estudio.

La tabla 1 muestra la cantidad de artículos obtenidos en cada clasificación:

Base de datos	Clasificación				
	1era	2da	3era	4ta	5ta
Scopus	195	102	99	96	74
IEEE	11	11	9	9	0
ACM	24	20	20	-	-
SciELO	2	2	2	2	2
NIH	2	2	2	2	1
Total	234	137	129	109	77

#### Criterios de inclusión y exclusión

La definición de criterios de inclusión y exclusión ayuda a garantizar la objetividad y reproducibilidad de la revisión, asegurando que los estudios sean relevantes y cumplan con estándares de calidad.<sup>(13)</sup> Por lo tanto, se definieron los siguientes criterios de inclusión: publicados entre el año 2019 y 2024; idioma español e inglés, artículos originales en IEEE, SCOPUS, ACM, SciELO; enfocados en la aplicación de IA, específicamente Deep Learning, para la detección de RD. En cuanto a los criterios de exclusión se establecieron los siguientes: artículos de revisión u otros tipos de fuentes secundarias; publicaciones duplicadas; artículos sin acceso al texto completo o no descargables.

#### Extracción de datos.

Tras la selección final de los 77 artículos, se procedió a la extracción de datos relevantes que incluyen la identificación de factores y variables considerados por los modelos, la evaluación de los algoritmos más efectivos, la precisión de estos modelos, y las limitaciones técnicas, éticas y legales que enfrenta la implementación de inteligencia artificial en la detección de retinopatía diabética. Esta metodología asegura una revisión exhaustiva y rigurosa, proporcionando una base sólida para evaluar la eficacia y los desafíos de la IA en el diagnóstico y tratamiento de la RD.

## RESULTADOS Y DISCUSIÓN

Después de seleccionar los artículos relevantes y realizar una revisión exhaustiva de cada uno de ellos, se procedió a responder las preguntas de investigación formuladas.

P1: ¿Cuáles son los factores o variables considerados por los modelos en la detección de RD?

Esta pregunta hace mención a los diferentes elementos que los modelos de IA analizan para detectar la RD. Es crucial entender qué factores y variables como características clínicas, atributos de imagen y parámetros demográficos se utilizan, ya que estos determinan la precisión y efectividad del diagnóstico. Conocer estos aspectos ayuda a mejorar los modelos y su aplicación en diversos contextos clínicos.

**Tabla 2.** Factores o variables considerados por los modelos en la detección de retinopatía diabética.

Factor/Variable	Artículos
Neovascularización	(14); (15); (16); (17); (18); (19); (20); (8); (21); (22); (23); (24); (25); (26); (27); (28); (29); (30); (31); (32); (33); (34); (35); (36); (37); (38); (39)
Edema macular	(40); (41); (42); (43); (44); (45); (46); (47); (15); (48); (16); (17); (49); (18); (50); (20); (8); (51); (52); (24); (26); (28); (53); (54); (55); (56); (57); (35); (58); (59); (60); (61); (62); (38); (39)
Cambios en la vascularización de la retina	(40); (41); (63); (64); (65); (66); (42); (43); (14); (44); (45); (67); (46); (47); (15); (3); (68); (69); (17); (49); (18); (1); (70); (19); (20); (71); (8); (51); (72); (22); (73); (25); (28); (53); (31); (32); (54); (33); (74); (35); (58); (60); (75); (61); (76); (62); (37); (38); (77)
Tamaño del disco óptico	(78); (4); (41); (63); (64); (65); (42); (67); (15); (79); (48); (69); (17); (49); (20); (8); (80); (23); (24); (26); (28); (29); (54); (34); (75); (61); (36); (37)
Microaneurismas	(78); (4); (41); (81); (63); (64); (65); (66); (42); (43); (14); (82); (44); (67); (46); (15); (79); (48); (16); (3); (68); (69); (17); (49); (18); (1); (70); (50); (83); (19); (20); (84); (71); (8); (51); (52); (21); (80); (22); (23); (24); (73); (25); (26); (28); (53); (29); (30); (32); (54); (85); (56); (33); (34); (74); (57); (35); (58); (59); (60); (75); (86); (61); (36); (76); (62); (37); (38); (77); (39)
Exudados	(78); (4); (41); (63); (64); (65); (66); (42); (14); (44); (67); (46); (15); (79); (48); (16); (68); (69); (17); (49); (18); (1); (70); (50); (83); (19); (20); (84); (71); (8); (51); (21); (80); (22); (23); (24); (73); (25); (26); (28); (53); (29); (30); (32); (54); (85); (56); (33); (34); (74); (57); (35); (59); (60); (75); (86); (61); (36); (76); (62); (37); (38); (77)

**Tabla 3.** Algoritmos para la detección temprana de la RD con IA

Algoritmos	Artículo(s)
ResNet 101	(40), (16), (30), (24), (59)
CNN	(78), (41), (68), (21), (62)
IDx-DR	(4), (45), (8), (25), (60)
Retinalyze	(4)
VeriSee DR	(65)
Deep Learning (DL)	(66), (79), (39)
EyeWisdom	(14)
DART (TeleDx)	(82), (77)
AI general	(44), (47), (73), (85)
Ensemble AI	(46)
SqueezeNet	(50)
AlexNet	(19)
Modified GoogLeNet	(20)
Grey Level Co-occurrence Matrix	(84)
VGG-16	(71)
EyeArt™	(51), (31)
EyeCheckup AI	(52)
Deep Convolutional Neural Network	(69)
Support Vector Machine (SVM)	(69), (68)
PNN	(68)
ExplAIin	(17)
Selena + Aurora	(53)
THEIA™	(55)
EBM y XGBoost	(32)
Medios AI	(57), (75)
PhelcomNet	(86)
Phoebus Algorithm	(61)
RetCAD AI	(33)
DeepDR	(74)
ResNet-50	(38)
DLA	(76)

La tabla 2 ofrece una visión detallada de los diferentes factores o variables consideradas por los modelos en la detección de RD. Los resultados indican que los microaneurismas son el factor más recurrentemente

abordado, con una presencia en 71 de los 77 artículos recopilados. Esto sugiere que los microaneurismas son una característica prominente y relevante en la detección y diagnóstico de RD según la literatura revisada. La alta incidencia de microaneurismas en los modelos puede indicar su importancia como marcador temprano de RD. Estas pequeñas dilataciones de los capilares son indicativas de daño vascular en la retina, algunas asociadas con la diabetes mellitus. Sin embargo, otros factores también son destacados en la literatura, como el edema macular y los cambios en la vascularización de la retina, que son presentes en 35 y 53 artículos respectivamente. Estos hallazgos sugieren que los modelos también prestan atención a la presencia de edema macular y cambios vasculares como indicadores clave de la progresión de la enfermedad. La inclusión de diferentes factores en los modelos refleja la diversidad de manifestaciones de la RD y la importancia de un enfoque integral en su detección y manejo clínico. La atención a los exudados y cambios en la vascularización refleja la necesidad de los modelos de IA de abordar tanto los signos tempranos como los indicativos de enfermedad avanzada.

P2: ¿Cuáles son los algoritmos más efectivos para la detección temprana de la RD utilizando IA?

Esta pregunta busca identificar los algoritmos específicos que han demostrado ser más efectivos en la detección temprana de la RD. Es importante conocer estos algoritmos para entender cuáles proporcionan mejores resultados en términos de sensibilidad, especificidad y precisión diagnóstica, lo que es crucial para optimizar el uso de la IA en el cuidado de la salud ocular.

La tabla 3 muestra una variedad de algoritmos utilizados en la detección temprana de la RD utilizando IA. Los algoritmos incluidos en la lista son representativos de las diferentes aproximaciones y enfoques utilizados en la detección de esta enfermedad. Entre los algoritmos más utilizados se encuentran los basados en redes neuronales convolucionales (CNN) y los basados en aprendizaje profundo (DL). Estos algoritmos han demostrado ser efectivos en la detección de RD debido a su capacidad para aprender patrones en imágenes y detectar cambios en la retina. Otro grupo de algoritmos incluye los basados en máquinas de aprendizaje supervisadas, como el SVM y el PNN. Estos algoritmos también han demostrado ser efectivos en la detección de RD, ya que pueden aprender a reconocer patrones en las imágenes y clasificarlas según su correspondencia con la enfermedad. La inclusión de algoritmos como EyeArt™, EyeCheckup AI y Medios AI en la lista sugiere que la detección temprana de la RD también puede realizarse utilizando herramientas de aprendizaje automático y sistemas de visión por computadora.

P3: ¿Cuál es la precisión de los modelos de IA en la detección de RD?

Esta pregunta examina cuán exactos son los modelos de IA en la detección de RD. Es esencial evaluar la precisión de estos modelos, ya que esto determina su viabilidad y utilidad en la práctica clínica. Conocer la precisión permite a los profesionales de la salud confiar en estos sistemas para el diagnóstico y manejo de la enfermedad.

**Tabla 4.** Precisión de los modelos de IA en la detección de RD

Precisión en % de algoritmo	Artículos (Algoritmos, Porcentaje)
< 80 %	<sup>(59)</sup> (ResNet 101, 79 %), <sup>(41)</sup> (CNN, 76 %), <sup>(86)</sup> (Medios AI, 78 %)
80 - 85 %	<sup>(16)</sup> (ResNet 101, 83 %), <sup>(78)</sup> (CNN, 84 %), <sup>(69)</sup> (DL, 82 %), <sup>(68)</sup> (SVM, 84 %), <sup>(69)</sup> (SVM, 83 %), <sup>(14)</sup> (EyeWisdom, 82 %), <sup>(50)</sup> (SqueezeNet, 84 %)
85 - 90 %	<sup>(30)</sup> (ResNet 101, 89 %), <sup>(68)</sup> (CNN, 87 %), <sup>(53)</sup> (Selena + Aurora, 86 %), <sup>(8)</sup> (IDx-DR, 88 %), <sup>(82)</sup> (DART, 88 %), <sup>(73)</sup> (AI general, 87 %), <sup>(75)</sup> (Medios AI, 87 %), <sup>(19)</sup> (AlexNet, 88 %), <sup>(79)</sup> (DL, 85 %), <sup>(32)</sup> (EBM y XGBoost, 89 %)
90 - 95 %	<sup>(40)</sup> (ResNet 101, 98 %), <sup>(62)</sup> (CNN, 92 %), <sup>(4)</sup> (IDx-DR, 95 %), <sup>(45)</sup> (IDx-DR, 92 %), <sup>(25)</sup> (IDx-DR, 93 %), <sup>(60)</sup> (IDx-DR, 91 %), <sup>(51)</sup> (EyeArt™, 95 %), <sup>(31)</sup> (EyeArt™, 90 %), <sup>(52)</sup> (EyeCheckup AI, 92 %), <sup>(84)</sup> (Grey Level Co-occurrence Matrix, 85 %), <sup>(71)</sup> (VGG-16, 91 %), <sup>(20)</sup> (Modified GoogLeNet, 90 %), <sup>(74)</sup> (DeepDR, 89 %), <sup>(44)</sup> (AI general, 94 %), <sup>(46)</sup> (Ensemble AI, 92 %), <sup>(76)</sup> (DART, 90 %)
95 - 100 %	<sup>(65)</sup> (VeriSee DR, 96 %), <sup>(29)</sup> (AI general, 97 %), <sup>(41)</sup> (CNN, 76 %), <sup>(20)</sup> (Modified GoogLeNet, 90 %), <sup>(61)</sup> (Phoebus Algorithm, 95 %), <sup>(36)</sup> (ResNet-50, 90 %), <sup>(37)</sup> (DLA, 92 %), <sup>(80)</sup> (EyeCheckup AI, 93 %)

La tabla 4 muestra la precisión de diferentes algoritmos de IA en la detección de RD. Al examinar los datos, se observa una distribución variada de la precisión entre los distintos algoritmos, con una amplia gama de porcentajes que van desde menos del 80 % hasta más del 95 %. Los algoritmos con una precisión inferior al 80 % podrían considerarse menos confiables para su implementación en la práctica clínica, ya que existe un mayor margen de error. Sin embargo, es importante reconocer que algunos de estos algoritmos, como ResNet 101 y CNN, se acercan al umbral del 80 %, sugiriendo un potencial para mejoras con ajustes o entrenamientos adicionales.

Por otro lado, los algoritmos con una precisión en el rango del 90 % al 95 %, como IDx-DR y EyeArt™, muestran un rendimiento notablemente sólido en la detección de RD. Estos resultados respaldan la viabilidad de utilizar estos algoritmos en la práctica clínica, ya que ofrecen una precisión alta y consistente que inspira confianza

en su capacidad diagnóstica. Los algoritmos con una precisión del 95 al 100 %, como VeriSee DR y AI general, son especialmente prometedores, ya que ofrecen una precisión alta en la detección de RD. Estos resultados sugieren que estos algoritmos tienen el potencial de ser herramientas altamente confiables y precisas para los profesionales de la salud en la detección y diagnóstico de la enfermedad.

P4: ¿Qué limitaciones técnicas o de implementación enfrentan los sistemas de IA en la detección de la RD?

Esta pregunta aborda los obstáculos técnicos y de implementación que dificultan el uso eficaz de los sistemas de IA en la detección de la RD. Identificar estas limitaciones es fundamental para desarrollar soluciones que mejoren la integración y el rendimiento de estos sistemas en entornos clínicos reales.

**Tabla 5.** Limitaciones en la detección de RD mediante sistemas de IA

Limitaciones técnicas o de implementación	Artículos
Dependencia de la calidad de las imágenes	(40), (4), (41), (81), (64), (65), (42), (43), (14), (44), (45), (46), (47), (79), (3), (68), (69), (17), (49), (18), (70), (50), (83), (19), (20), (71), (51), (72), (21), (22), (73), (28), (53), (31), (54), (55), (85), (33), (74), (58), (60), (61), (76), (62), (37), (38), (77)
Variabilidad en la interpretación de las características retinianas	(40), (78), (4), (41), (81), (63), (64), (65), (42), (43), (82), (45), (67), (47), (79), (3), (68), (69), (17), (49), (18), (1), (70), (50), (19), (20), (71), (8), (51), (72), (21), (22), (73), (25), (28), (53), (29), (31), (32), (54), (55), (85), (33), (74), (57), (35), (58), (60), (75), (61), (36), (62), (37), (38), (77)
Costos de implementación y mantenimiento	(78), (41), (81), (63), (64), (65), (42), (43), (14), (44), (45), (46), (47), (15), (79), (3), (68), (69), (17), (49), (18), (1), (70), (50), (83), (19), (20), (8), (51), (72), (21), (20), (73), (25), (28), (53), (31), (32), (55), (85), (33), (74), (57), (35), (58), (60), (75), (61), (36), (76), (62), (37), (38), (77)
Acceso limitado a datos de calidad	(40), (4), (81), (64), (66), (43), (14), (82), (44), (45), (46), (47), (15), (79), (3), (68), (69), (17), (49), (1), (70), (83), (19), (20), (8), (51), (72), (21), (20), (22), (24), (73), (25), (28), (53), (31), (32), (54), (55), (85), (33), (74), (57), (35), (58), (59), (60), (61), (76), (62), (37), (38), (77)
Falta de integración con sistemas de registros médicos electrónicos	(40), (78), (4), (81), (63), (64), (65), (42), (43), (14), (82), (45), (46), (47), (15), (79), (3), (68), (69), (17), (49), (18), (1), (70), (50), (83), (19), (20), (71), (8), (51), (72), (21), (20), (80), (22), (73), (25), (28), (53), (31), (32), (54), (55), (85), (33), (74), (57), (35), (58), (60), (61), (76), (62), (37), (38), (77)

De acuerdo a la tabla 5, entre las principales limitaciones se encuentran la dependencia de la calidad de las imágenes, la variabilidad en la interpretación de las características retinianas y los costos de implementación y mantenimiento. La calidad de las imágenes de la retina es crucial para la precisión de los diagnósticos, y la falta de imágenes de alta calidad puede reducir la efectividad de los sistemas de IA en la detección de RD. Además, la variabilidad en la interpretación de las características retinianas puede surgir debido a diferencias en la formación de los algoritmos y en la interpretación humana de las características de las imágenes, generando resultados inconsistentes y potencialmente erróneos.

Además, los costos de implementación y mantenimiento son un factor importante a considerar. La inversión necesaria para desarrollar, implementar y mantener sistemas de IA en entornos clínicos puede ser significativa, limitando su adopción en áreas con recursos limitados. El acceso limitado a datos de calidad y la falta de integración con sistemas de registros médicos electrónicos también emergen como desafíos. Por lo tanto, es fundamental desarrollar soluciones que aborden estas limitaciones para mejorar la eficacia y la adopción de los sistemas de inteligencia artificial en la detección de retinopatía diabética.

**Tabla 6.** Desafíos del uso de algoritmos de IA en el diagnóstico y tratamiento de la RD

Desafío	Artículos
Privacidad y seguridad de los datos del paciente	(40), (4), (41), (81), (64), (65), (42), (43), (14), (44), (45), (46), (47), (79), (3), (68), (69), (17), (49), (18), (70), (50), (83), (19), (20), (71), (51), (72), (21), (22), (73), (28), (53), (31), (54), (55), (85), (33), (74), (58), (60), (61), (76), (62), (37), (38), (77)
Responsabilidad en caso de errores de diagnóstico	(40), (78), (4), (41), (81), (63), (64), (65), (42), (43), (82), (45), (67), (47), (79), (3), (68), (69), (17), (49), (18), (1), (70), (50), (19), (20), (71), (8), (51), (72), (21), (22), (73), (25), (28), (53), (29), (31), (32), (54), (55), (85), (33), (74), (57), (35), (58), (60), (75), (61), (36), (62), (37), (38), (77)
Sesgo algorítmico en la atención médica	(40), (78), (41), (81), (63), (64), (65), (42), (43), (14), (82), (45), (67), (47), (15), (79), (48), (3), (68), (17), (49), (18), (1), (70), (50), (19), (20), (84), (71), (8), (51), (52), (21), (80), (23), (73), (25), (28), (29), (30), (31), (54), (85), (33), (74), (57), (59), (60), (75), (86), (36), (62), (37), (38), (77)
Consentimiento informado y transparencia en el uso de IA	(78), (4), (41), (81), (64), (65), (42), (43), (14), (82), (45), (67), (46), (47), (15), (79), (48), (3), (68), (69), (17), (49), (18), (1), (70), (50), (83), (20), (84), (71), (8), (51), (72), (52), (21), (80), (23), (73), (25), (28), (29), (30), (31), (54), (85), (33), (74), (57), (35), (59), (75), (86), (36), (62), (38), (77)
Regulaciones sobre el uso de datos médicos para fines de investigación y desarrollo.	(40), (78), (4), (41), (81), (63), (64), (65), (42), (43), (14), (82), (44), (45), (67), (46), (47), (15), (79), (48), (3), (68), (69), (17), (49), (18), (1), (70), (50), (83), (20), (84), (71), (8), (51), (72), (52), (21), (80), (23), (73), (25), (28), (29), (30), (31), (54), (85), (33), (74), (57), (35), (59), (85), (33), (74), (57), (59), (75), (86), (36), (62), (38), (39)

P5: ¿Qué desafíos éticos y legales plantea el uso de algoritmos de IA en el diagnóstico y tratamiento de la RD? Esta pregunta explora los problemas éticos y legales asociados con el uso de algoritmos de IA en el diagnóstico y

tratamiento de la RD. Es importante considerar estos desafíos para garantizar que la implementación de la IA sea segura, justa y cumpla con las regulaciones legales, protegiendo así a los pacientes y profesionales de la salud. Según la tabla 6, la principal preocupación gira en torno a la privacidad y seguridad de los datos del paciente, destacando la necesidad de proteger la información sensible. Además, la responsabilidad en caso de errores de diagnóstico es un tema crítico que requiere una clara definición de roles y responsabilidades entre los profesionales de la salud y los desarrolladores de algoritmos. El sesgo algorítmico también es una preocupación significativa, ya que la falta de diversidad en los datos de entrenamiento puede conducir a decisiones médicas erróneas. Por lo tanto, es esencial abordar este desafío para garantizar una atención médica equitativa y justa para todos los pacientes.

La transparencia y el consentimiento informado son elementos importantes para construir una relación de confianza entre los pacientes y los sistemas de IA. Los pacientes deben comprender cómo se utilizan sus datos y las implicaciones del uso de algoritmos de IA en su atención médica, resaltando la necesidad de una comunicación clara por parte de los profesionales de la salud. Finalmente, las regulaciones sobre el uso de datos médicos para fines de investigación y desarrollo son necesarias para garantizar que el uso de la IA en la atención médica sea ético y responsable. Estas regulaciones deben establecer estándares claros para proteger los derechos de los pacientes y garantizar la integridad y la ética en la investigación médica.

## CONCLUSIONES

La revisión sistemática ha demostrado que la IA, específicamente el aprendizaje profundo, es una alternativa tecnológica eficaz para la detección de la RD. Diversos algoritmos, como ResNet, CNN, IDx-DR y EyeArt™, han reportado una alta precisión, con porcentajes superiores al 90 % en la identificación de características de la RD. Asimismo, los modelos de IA consideran factores como microaneurismas, edema macular, cambios en la vascularización de la retina y tamaño del disco óptico. Estos algoritmos han demostrado su eficacia en la detección temprana de la RD, lo que facilita un tratamiento oportuno y mejora los resultados clínicos.

Sin embargo, existen limitaciones técnicas y de implementación que deben abordarse. La dependencia de la calidad de las imágenes, la variabilidad en la interpretación de las características retinianas, los costos de implementación y mantenimiento, el acceso limitado a datos de calidad, y la falta de integración con sistemas de registros médicos electrónicos son algunos de los desafíos identificados. Además, surgen preocupaciones éticas y legales, como la privacidad y seguridad de los datos del paciente, la responsabilidad en caso de errores de diagnóstico, el sesgo algorítmico, el consentimiento informado y la transparencia en el uso de IA, y las regulaciones sobre el uso de datos médicos para fines de investigación y desarrollo.

Aunque la revisión sistemática ha proporcionado resultados relevantes, es importante reconocer algunas limitaciones. La búsqueda se restringió a bases de datos específicas y a un rango de años determinado, lo que podría haber excluido estudios relevantes. Futuras investigaciones deberían enfocarse en ampliar las fuentes de información a lo largo de varias décadas, utilizar bases de datos adicionales y seleccionar técnicas específicas de IA para realizar un análisis más detallado.

## REFERENCIAS BIBLIOGRÁFICAS

1. Cleland CR, Bascaran C, Makupa W, Shilio B, Sandi FA, Philippin H, et al. Artificial intelligence-supported diabetic retinopathy screening in Tanzania: rationale and design of a randomised controlled trial. *BMJ Open* [Internet]. 2024 Jan;14(1):e075055. Available from: <https://bmjopen.bmjjournals.org/content/bmjopen/14/1/e075055.full.pdf>
2. Padhy S, Takkar B, Chawla R, Kumar A. Artificial intelligence in diabetic retinopathy: A natural step to the future. *Indian J Ophthalmol* [Internet]. 2019;67(7):1004. Available from: [https://journals.lww.com/10.4103/ijo.IJO\\_1989\\_18](https://journals.lww.com/10.4103/ijo.IJO_1989_18)
3. Huang XM, Yang BF, Zheng WL, Liu Q, Xiao F, Ouyang PW, et al. Cost-effectiveness of artificial intelligence screening for diabetic retinopathy in rural China. *BMC Health Serv Res* [Internet]. 2022 Feb 25;22(1):260. Available from: <https://bmchealthservres.biomedcentral.com/articles/10.1186/s12913-022-07655-6>
4. Grzybowski A, Brona P. Analysis and Comparison of Two Artificial Intelligence Diabetic Retinopathy Screening Algorithms in a Pilot Study: IDx-DR and Retinalyze. *J Clin Med* [Internet]. 2021 May 27;10(11):2352. Available from: <https://www.mdpi.com/2077-0383/10/11/2352>
5. Grauslund J. Diabetic retinopathy screening in the emerging era of artificial intelligence. *Diabetologia* [Internet]. 2022 Sep;65(9):1415-23. Available from: <https://link.springer.com/10.1007/s00125-022-05727-0>
6. Sheng B, Chen X, Li T, Ma T, Yang Y, Bi L, et al. An overview of artificial intelligence in diabetic retinopathy and other ocular diseases. *Front Public Heal* [Internet]. 2022 Oct 28;10. Available from: <https://www.frontiersin.org/articles/10.3389/fpubh.2022.971943/full>

7. Bidwai P, Gite S, Pahuja K, Kotecha K. A Systematic Literature Review on Diabetic Retinopathy Using an Artificial Intelligence Approach. *Big Data Cogn Comput* [Internet]. 2022 Dec 8;6(4):152. Available from: <https://www.mdpi.com/2504-2289/6/4/152>
8. Nakayama LF, Ribeiro LZ, Malerbi FK, Regatieri CVS. Ophthalmology and Artificial Intelligence: Present or Future? A Diabetic Retinopathy Screening Perspective of the Pursuit for Fairness. *Front Ophthalmol* [Internet]. 2022 May 10;2. Available from: <https://www.frontiersin.org/articles/10.3389/foph.2022.898181/full>
9. Huemer J, Wagner SK, Sim DA. The Evolution of Diabetic Retinopathy Screening Programmes: A Chronology of Retinal Photography from 35 mm Slides to Artificial Intelligence. *Clin Ophthalmol* [Internet]. 2020 Jul;Volume 14:2021-35. Available from: <https://www.dovepress.com/the-evolution-of-diabetic-retinopathy-screening-programmes-a-chronolog-peer-reviewed-article-OPTH>
10. Rajesh AE, Davidson OQ, Lee CS, Lee AY. Artificial Intelligence and Diabetic Retinopathy: AI Framework, Prospective Studies, Head-to-head Validation, and Cost-effectiveness. *Diabetes Care* [Internet]. 2023 Oct 1;46(10):1728-39. Available from: <https://diabetesjournals.org/care/article/46/10/1728/153626/Artificial-Intelligence-and-Diabetic-Retinopathy>
11. Senapati A, Tripathy HK, Sharma V, Gandomi AH. Artificial intelligence for diabetic retinopathy detection: A systematic review. *Informatics Med Unlocked* [Internet]. 2024;45:101445. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S2352914824000017>
12. Li S, Zhao R, Zou H. Artificial intelligence for diabetic retinopathy. *Chin Med J (Engl)* [Internet]. 2022 Feb 5;135(3):253-60. Available from: <https://journals.lww.com/10.1097/CM9.0000000000001816>
13. Kitchenham B, Charters S. Guidelines for performing Systematic Literature Reviews in Software Engineering. Keele Univ y Univ Durham [Internet]. 2007; Available from: [https://legacyfileshare.elsevier.com/promis\\_misc/525444systematicreviewsguide.pdf](https://legacyfileshare.elsevier.com/promis_misc/525444systematicreviewsguide.pdf)
14. Pei X, Yao X, Yang Y, Zhang H, Xia M, Huang R, et al. Efficacy of artificial intelligence-based screening for diabetic retinopathy in type 2 diabetes mellitus patients. *Diabetes Res Clin Pract* [Internet]. 2022 Feb;184(109190):109190. Available from: [https://www.diabetesresearchclinicalpractice.com/article/S0168-8227\(22\)00002-X/fulltext](https://www.diabetesresearchclinicalpractice.com/article/S0168-8227(22)00002-X/fulltext)
15. Lee AY, Yanagihara RT, Lee CS, Blazes M, Jung HC, Chee YE, et al. Multicenter, Head-to-Head, Real-World Validation Study of Seven Automated Artificial Intelligence Diabetic Retinopathy Screening Systems. *Diabetes Care* [Internet]. 2021 May 1;44(5):1168-75. Available from: <https://diabetesjournals.org/care/article/44/5/1168/138752/Multicenter-Head-to-Head-Real-World-Validation>
16. Gomez Rossi J, Rojas-Perilla N, Krois J, Schwendicke F. Cost-effectiveness of Artificial Intelligence as a Decision-Support System Applied to the Detection and Grading of Melanoma, Dental Caries, and Diabetic Retinopathy. *JAMA Netw Open* [Internet]. 2022 Mar 15;5(3):e220269.
17. Quellec G, Al Hajj H, Lamard M, Conze PH, Massin P, Cochener B. ExplAI: Explanatory artificial intelligence for diabetic retinopathy diagnosis. *Med Image Anal* [Internet]. 2021 Aug;72:102118. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S136184152100164X>
18. Wolf RM, Channa R, Liu TYA, Zehra A, Bromberger L, Patel D, et al. Autonomous artificial intelligence increases screening and follow-up for diabetic retinopathy in youth: the ACCESS randomized control trial. *Nat Commun* [Internet]. 2024 Jan 11;15(1):421. Available from: <https://www.nature.com/articles/s41467-023-44676-z>
19. Salma A, Bustamam A, Yudantha A, Victor A, Mangunwardoyo W. Artificial Intelligence Approach in Multiclass Diabetic Retinopathy Detection Using Convolutional Neural Network and Attention Mechanism. *Int J Adv Soft Comput its Appl* [Internet]. 2021 Dec 30;13(3):101-14. Available from: <http://ijasca.zuj.edu.jo/PapersUploaded/2021.3.8.pdf>
20. Takahashi H, Tampo H, Arai Y, Inoue Y, Kawashima H. Applying artificial intelligence to disease staging: Deep learning for improved staging of diabetic retinopathy. Mori K, editor. *PLoS One* [Internet]. 2017 Jun 22;12(6):e0179790. Available from: <https://dx.plos.org/10.1371/journal.pone.0179790>

21. Rajamani S, Sasikala S. Artificial Intelligence Approach for Diabetic Retinopathy Severity Detection. *Informatica* [Internet]. 2023 Jan 5;46(8). Available from: <https://www.informatica.si/index.php/informatica/article/view/4425>
22. Qian X, Jingying H, Xian S, Yuqing Z, Lili W, Baorui C, et al. The effectiveness of artificial intelligence-based automated grading and training system in education of manual detection of diabetic retinopathy. *Front Public Heal* [Internet]. 2022 Nov 7;10. Available from: <https://www.frontiersin.org/articles/10.3389/fpubh.2022.1025271/full>
23. Hao Z, Cui S, Zhu Y, Shao H, Huang X, Jiang X, et al. Application of non-mydriatic fundus examination and artificial intelligence to promote the screening of diabetic retinopathy in the endocrine clinic: an observational study of T2DM patients in Tianjin, China. *Ther Adv Chronic Dis* [Internet]. 2020 Jan 10;11:204062232094241. Available from: <http://journals.sagepub.com/doi/10.1177/2040622320942415>
24. Liu YF, Fei FQ, Chen NM, Zhu ZT, Fei XZ. Research progress in artificial intelligence assisted diabetic retinopathy diagnosis. *Int J Ophthalmol* [Internet]. 2023 Sep 18;16(9):1395-405. Available from: [http://ies.ijo.cn/gjyken/ch/reader/view\\_abstract.aspx?file\\_no=20230905&flag=1](http://ies.ijo.cn/gjyken/ch/reader/view_abstract.aspx?file_no=20230905&flag=1)
25. Cuadros J. The Real-World Impact of Artificial Intelligence on Diabetic Retinopathy Screening in Primary Care. *J Diabetes Sci Technol* [Internet]. 2021 May 24;15(3):664-5. Available from: <http://journals.sagepub.com/doi/10.1177/1932296820914287>
26. Han R, Yu W, Chen H, Chen Y. Using artificial intelligence reading label system in diabetic retinopathy grading training of junior ophthalmology residents and medical students. *BMC Med Educ* [Internet]. 2022 Dec 9;22(1):258. Available from: <https://bmcmededuc.biomedcentral.com/articles/10.1186/s12909-022-03272-3>
27. Li H, Li G, Li N, Liu C, Yuan Z, Gao Q, et al. Cost-effectiveness analysis of artificial intelligence-based diabetic retinopathy screening in rural China based on the Markov model. Raafat KA, editor. *PLoS One* [Internet]. 2023 Nov 16;18(11):e0291390. Available from: <https://dx.plos.org/10.1371/journal.pone.0291390>
28. Xie Y, Gunasekeran D V, Balaskas K, Keane PA, Sim DA, Bachmann LM, et al. Health Economic and Safety Considerations for Artificial Intelligence Applications in Diabetic Retinopathy Screening. *Transl Vis Sci Technol* [Internet]. 2020 Apr 13;9(2):22. Available from: <https://tvst.arvojournals.org/article.aspx?articleid=2764675>
29. Barakat AA, Mobarak O, Javaid HA, Awad MR, Hamweyah K, Ouban A, et al. The application of artificial intelligence in diabetic retinopathy screening: a Saudi Arabian perspective. *Front Med* [Internet]. 2023 Nov 22;10. Available from: <https://www.frontiersin.org/articles/10.3389/fmed.2023.1303300/full>
30. Hao Z, Xu R, Huang X, Ren X, Li H, Shao H. Application and observation of artificial intelligence in clinical practice of fundus screening for diabetic retinopathy with non-mydriatic fundus photography: a retrospective observational study of T2DM patients in Tianjin, China. *Ther Adv Chronic Dis* [Internet]. 2022 Jan 19;13:204062232210973. Available from: <http://journals.sagepub.com/doi/10.1177/2040622322109735>
31. Ipp E, Liljenquist D, Bode B, Shah VN, Silverstein S, Regillo CD, et al. Pivotal Evaluation of an Artificial Intelligence System for Autonomous Detection of Referrable and Vision-Threatening Diabetic Retinopathy. *JAMA Netw Open* [Internet]. 2021 Nov 15;4(11):e2134254. Available from: <https://jamanetwork.com/journals/jamanetworkopen/fullarticle/2786132>
32. Yagin FH, Yasar S, Gormez Y, Yagin B, Pinar A, Alkhateeb A, et al. Explainable Artificial Intelligence Paves the Way in Precision Diagnostics and Biomarker Discovery for the Subclass of Diabetic Retinopathy in Type 2 Diabetics. *Metabolites* [Internet]. 2023 Dec 18;13(12):1204. Available from: <https://www.mdpi.com/2218-1989/13/12/1204>
33. Komatsu K, Sano K, Fukai K, Nakagawa R, Nakagawa T, Tatemichi M, et al. Associated factors of diabetic retinopathy by artificial intelligence evaluation of fundus images in Japan. *Sci Rep* [Internet]. 2023 Nov 13;13(1):19742. Available from: <https://www.nature.com/articles/s41598-023-47270-x>
34. Hu W, Joseph S, Li R, Woods E, Sun J, Shen M, et al. Population impact and cost-effectiveness of artificial intelligence-based diabetic retinopathy screening in people living with diabetes in Australia: a cost effectiveness analysis. *eClinicalMedicine* [Internet]. 2024 Jan;67:102387. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S2589537023005643>

35. Scanzera AC, Beversluis C, Potharazu A V., Bai P, Leifer A, Cole E, et al. Planning an artificial intelligence diabetic retinopathy screening program: a human-centered design approach. *Front Med [Internet]*. 2023 Jul 7;10. Available from: <https://www.frontiersin.org/articles/10.3389/fmed.2023.1198228/full>
36. Ursin F, Timmermann C, Orzechowski M, Steger F. Diagnosing Diabetic Retinopathy With Artificial Intelligence: What Information Should Be Included to Ensure Ethical Informed Consent? *Front Med [Internet]*. 2021 Jul 21;8. Available from: <https://www.frontiersin.org/articles/10.3389/fmed.2021.695217/full>
37. Wong TY, Sabanayagam C. Strategies to Tackle the Global Burden of Diabetic Retinopathy: From Epidemiology to Artificial Intelligence. *Ophthalmologica [Internet]*. 2020;243(1):9-20. Available from: <https://karger.com/OPH/article/doi/10.1159/000502387>
38. Shahsuvaryan ML. Is it time to consider teleophthalmology as a game-changer in the management of diabetic retinopathy? *Rev Bras Oftalmol [Internet]*. 2023 Sep 1;82. Available from: <https://www.rbojournal.org/en/article/is-it-time-to-consider-teleophthalmology-as-a-game-changer-in-the-management-of-diabetic-retinopathy/>
39. Zhelev Z, Peters J, Rogers M, Allen M, Kijauskaitė G, Seedat F, et al. Test accuracy of artificial intelligence-based grading of fundus images in diabetic retinopathy screening: A systematic review. *J Med Screen [Internet]*. 2023 Sep 9;30(3):97-112. Available from: <http://journals.sagepub.com/doi/10.1177/09691413221144382>
40. Liu R, Li Q, Xu F, Wang S, He J, Cao Y, et al. Application of artificial intelligence-based dual-modality analysis combining fundus photography and optical coherence tomography in diabetic retinopathy screening in a community hospital. *Biomed Eng Online [Internet]*. 2022 Dec 20;21(1):47. Available from: <https://biomedical-engineering-online.biomedcentral.com/articles/10.1186/s12938-022-01018-2#Sec1>
41. Lin S, Ma Y, Xu Y, Lu L, He J, Zhu J, et al. Artificial Intelligence in Community-Based Diabetic Retinopathy Telemedicine Screening in Urban China: Cost-effectiveness and Cost-Utility Analyses With Real-world Data. *JMIR Public Heal Surveill [Internet]*. 2023 Feb 23;9(9):e41624. Available from: <https://pubmed.ncbi.nlm.nih.gov/36821353/>
42. Wolf RM, Liu TYA, Thomas C, Prichett L, Zimmer-Galler I, Smith K, et al. The SEE Study: Safety, Efficacy, and Equity of Implementing Autonomous Artificial Intelligence for Diagnosing Diabetic Retinopathy in Youth. *Diabetes Care [Internet]*. 2021 Mar 1;44(3):781-7. Available from: <https://diabetesjournals.org/care/article/44/3/781/138584/The-SEE-Study-Safety-Efficacy-and-Equity-of>
43. Scheetz J, Koca D, McGuinness M, Holloway E, Tan Z, Zhu Z, et al. Real-world artificial intelligence-based opportunistic screening for diabetic retinopathy in endocrinology and indigenous healthcare settings in Australia. *Sci Rep [Internet]*. 2021 Aug 4;11(1):15808. Available from: <https://www.nature.com/articles/s41598-021-94178-5>
44. He J, Cao T, Xu F, Wang S, Tao H, Wu T, et al. Artificial intelligence-based screening for diabetic retinopathy at community hospital. *Eye [Internet]*. 2020 Mar 27;34(3):572-6. Available from: <https://www.nature.com/articles/s41433-019-0562-4#citeas>
45. Shah A, Clarida W, Amelon R, Hernaez-Ortega MC, Navea A, Morales-Olivas J, et al. Validation of Automated Screening for Referable Diabetic Retinopathy With an Autonomous Diagnostic Artificial Intelligence System in a Spanish Population. *J Diabetes Sci Technol [Internet]*. 2021 May 16;15(3):655-63. Available from: <http://journals.sagepub.com/doi/10.1177/1932296820906212>
46. Bellemo V, Lim ZW, Lim G, Nguyen QD, Xie Y, Yip MYT, et al. Artificial intelligence using deep learning to screen for referable and vision-threatening diabetic retinopathy in Africa: a clinical validation study. *Lancet Digit Heal [Internet]*. 2019 May;1(1):e35-44. Available from: [https://www.thelancet.com/journals/landig/article/PIIS2589-7500\(19\)30004-4/fulltext#](https://www.thelancet.com/journals/landig/article/PIIS2589-7500(19)30004-4/fulltext#)
47. Dong X, Du S, Zheng W, Cai C, Liu H, Zou J. Evaluation of an Artificial Intelligence System for the Detection of Diabetic Retinopathy in Chinese Community Healthcare Centers. *Front Med [Internet]*. 2022 Apr 11;9:883462. Available from: <https://www.frontiersin.org/journals/medicine/articles/10.3389/fmed.2022.883462/full>
48. Wang H, Meng X, Tang Q, Hao Y, Luo Y, Li J. Development and Application of a Standardized Testset for an Artificial Intelligence Medical Device Intended for the Computer-Aided Diagnosis of Diabetic Retinopathy. Xu Y, editor. *J Healthc Eng [Internet]*. 2023 Jan 8;2023(1). Available from: <https://onlinelibrary.wiley.com/doi/epdf/10.1155/2023/7139560>

49. Xie Q, Liu Y, Huang H, Hong B, Wang J, Han H, et al. An innovative method for screening and evaluating the degree of diabetic retinopathy and drug treatment based on artificial intelligence algorithms. *Pharmacol Res* [Internet]. 2020 Sep;159:104986. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S1043661820312949>
50. Obayya M, Nemri N, Nour MK, Al Duhyayim M, Mohsen H, Rizwanullah M, et al. Explainable Artificial Intelligence Enabled TeleOphthalmology for Diabetic Retinopathy Grading and Classification. *Appl Sci* [Internet]. 2022 Aug 31;12(17):8749. Available from: <https://www.mdpi.com/2076-3417/12/17/8749>
51. Rajalakshmi R, Subashini R, Anjana RM, Mohan V. Automated diabetic retinopathy detection in smartphone-based fundus photography using artificial intelligence. *Eye* [Internet]. 2018 Jun 9;32(6):1138-44. Available from: <https://www.nature.com/articles/s41433-018-0064-9>
52. Doğan ME, Bilgin AB, Sari R, Bulut M, Akar Y, Aydemir M. Head to head comparison of diagnostic performance of three non-mydiatic cameras for diabetic retinopathy screening with artificial intelligence. *Eye* [Internet]. 2024 Jun 11;38(9):1694-701. Available from: <https://www.nature.com/articles/s41433-024-03000-9>
53. Lupidi M, Danieli L, Fruttini D, Nicolai M, Lassandro N, Chhablani J, et al. Artificial intelligence in diabetic retinopathy screening: clinical assessment using handheld fundus camera in a real-life setting. *Acta Diabetol* [Internet]. 2023 May 8;60(8):1083-8. Available from: <https://link.springer.com/10.1007/s00592-023-02104-0>
54. Korn Mallerbi F, Barreto Melo G. Feasibility of screening for diabetic retinopathy using artificial intelligence, Brazil. *Bull World Health Organ* [Internet]. 2022 Oct 1;100(10):643-7. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9511671/pdf/BLT.22.288580.pdf>
55. Vaghefi E, Yang S, Xie L, Hill S, Schmiedel O, Murphy R, et al. THEIATM development, and testing of artificial intelligence-based primary triage of diabetic retinopathy screening images in New Zealand. *Diabet Med* [Internet]. 2021 Apr 27;38(4). Available from: <https://onlinelibrary.wiley.com/doi/10.1111/dme.14386>
56. Penha FM, Priotto BM, Hennig F, Przysiezny B, Wiethorn BA, Orsi J, et al. Single retinal image for diabetic retinopathy screening: performance of a handheld device with embedded artificial intelligence. *Int J Retin Vitr* [Internet]. 2023 Jul 10;9(1):41. Available from: <https://journalretinavitreous.biomedcentral.com/articles/10.1186/s40942-023-00477-6>
57. Natarajan S, Jain A, Krishnan R, Rogye A, Sivaprasad S. Diagnostic Accuracy of Community-Based Diabetic Retinopathy Screening With an OfflineArtificial Intelligence System on a Smartphone. *JAMA Ophthalmol* [Internet]. 2019 Oct 1;137(10):1182. Available from: <https://jamanetwork.com/journals/jamaophthalmology/fullarticle/2747315>
58. Kemp O, Bascaran C, Cartwright E, McQuillan L, Matthew N, Shillingford-Ricketts H, et al. Real-world evaluation of smartphone-based artificial intelligence to screen for diabetic retinopathy in Dominica: a clinical validation study. *BMJ Open Ophthalmol* [Internet]. 2023 Dec 21;8(1):e001491. Available from: <https://bmjophth.bmj.com/lookup/doi/10.1136/bmjophth-2023-001491>
59. Surya J, Garima, Pandy N, Hyungtaek Rim T, Lee G, Priya MS, et al. Efficacy of deep learning-based artificial intelligence models in screening and referring patients with diabetic retinopathy and glaucoma. *Indian J Ophthalmol* [Internet]. 2023 Aug;71(8):3039-45. Available from: [https://journals.lww.com/10.4103/IJO.IJO\\_11\\_23](https://journals.lww.com/10.4103/IJO.IJO_11_23)
60. Grzybowski A, Rao DP, Brona P, Negiloni K, Krzywicki T, Savoy FM. Diagnostic Accuracy of Automated Diabetic Retinopathy Image Assessment Softwares: IDx-DR and Medios Artificial Intelligence. *Ophthalmic Res* [Internet]. 2023;66(1):1286-92. Available from: <https://karger.com/ORE/article/doi/10.1159/000534098>
61. Ruan S, Hu WT, Jia HX, Wang SS, Song ML, Shen MX, et al. A new handheld fundus camera combined with visual artificial intelligence facilitates diabetic retinopathy screening. *Int J Ophthalmol* [Internet]. 2022 Apr 18;15(4):620-7. Available from: [http://ies.ijo.cn/gjyken/ch/reader/view\\_abstract.aspx?file\\_no=20220416&flag=1](http://ies.ijo.cn/gjyken/ch/reader/view_abstract.aspx?file_no=20220416&flag=1)
62. Shah P, Mishra D, Shanmugam M, Doshi B, Jayaraj H, Ramanjulu R. Validation of Deep Convolutional Neural Network-based algorithm for detection of diabetic retinopathy - Artificial intelligence versus clinician for screening. *Indian J Ophthalmol* [Internet]. 2020;68(2):398. Available from: [https://journals.lww.com/ijo/Fulltext/2020/68020/Validation\\_of\\_Deep\\_Convolutional\\_Neural.32.aspx](https://journals.lww.com/ijo/Fulltext/2020/68020/Validation_of_Deep_Convolutional_Neural.32.aspx)

63. Dow ER, Chen KM, Zhao C, Knapp A, Phadke A, Weng K, et al. Artificial Intelligence Improves Patient Follow-Up in a Diabetic Retinopathy Screening Program. *Clin Ophthalmol* [Internet]. 2023 Nov;Volume 17:3323-30. Available from: <https://www.dovepress.com/artificial-intelligence-improves-patient-follow-up-in-a-diabetic-retin-peer-reviewed-fulltext-article-OPTH>
64. Kanagasingam Y, Xiao D, Vignarajan J, Preetham A, Tay-Kearney ML, Mehrotra A. Evaluation of Artificial Intelligence-Based Grading of Diabetic Retinopathy in Primary Care. *JAMA Netw Open* [Internet]. 2018 Sep 28;1(5):e182665.
65. Tsai MJ, Hsieh YT, Tsai CH, Chen M, Hsieh AT, Tsai CW, et al. Cross-Camera External Validation for Artificial Intelligence Software in Diagnosis of Diabetic Retinopathy. Li T, editor. *J Diabetes Res* [Internet]. 2022 Mar 9;2022(1):1-5. Available from: <https://www.hindawi.com/journals/jdr/2022/5779276/>
66. Zhang Y, Shi J, Peng Y, Zhao Z, Zheng Q, Wang Z, et al. Artificial intelligence-enabled screening for diabetic retinopathy: a real-world, multicenter and prospective study. *BMJ Open Diabetes Res Care* [Internet]. 2020 Oct 21;8(1):e001596. Available from: <https://drc.bmjjournals.org/content/8/1/e001596>
67. Wewetzer L, Held LA, Goetz K, Steinhäuser J. Determinants of the implementation of artificial intelligence-based screening for diabetic retinopathy—a cross-sectional study with general practitioners in Germany. *Digit Heal* [Internet]. 2023 Jan 30;9:205520762311766. Available from: <https://journals.sagepub.com/doi/10.1177/20552076231176644>
68. Al-hazaimeh OM, Abu-Ein A, Tahat N, Al-Smadi M, Al-Nawashi M. Combining Artificial Intelligence and Image Processing for Diagnosing Diabetic Retinopathy in Retinal Fundus Images. *Int J Online Biomed Eng* [Internet]. 2022 Oct 19;18(13):131-51. Available from: <https://online-journals.org/index.php/i-joe/article/view/33985/12091>
69. Katada Y, Ozawa N, Masayoshi K, Ofuji Y, Tsubota K, Kurihara T. Automatic screening for diabetic retinopathy in interracial fundus images using artificial intelligence. *Intell Med* [Internet]. 2020 Dec;3-4(100024):100024. Available from: <https://online-journals.org/index.php/i-joe/article/view/33985/12091>
70. Vidal-Alaball J, Royo Fibla D, Zapata MA, Marin-Gomez FX, Solans Fernandez O. Artificial Intelligence for the Detection of Diabetic Retinopathy in Primary Care: Protocol for Algorithm Development. *JMIR Res Protoc* [Internet]. 2019 Feb 1;8(2):e12539. Available from: <http://www.researchprotocols.org/2019/2/e12539/>
71. Crane AB, Choudhry HS, Dastjerdi MH. Effect of simulated cataract on the accuracy of artificial intelligence in detecting diabetic retinopathy in color fundus photos. *Indian J Ophthalmol* [Internet]. 2024 Jan;72(Suppl 1):S42-5. Available from: [https://journals.lww.com/10.4103/IJO.IJO\\_1163\\_23](https://journals.lww.com/10.4103/IJO.IJO_1163_23)
72. Gopalakrishnan N, Joshi A, Chhablani J, Yadav NK, Reddy NG, Rani PK, et al. Recommendations for initial diabetic retinopathy screening of diabetic patients using large language model-based artificial intelligence in real-life case scenarios. *Int J Retin Vitre* [Internet]. 2024 Jan 24;10(1):11. Available from: <https://journalretinavitreous.biomedcentral.com/articles/10.1186/s40942-024-00533-9>
73. Xie Y, Nguyen QD, Hamzah H, Lim G, Bellemo V, Gunasekeran D V, et al. Artificial intelligence for teleophthalmology-based diabetic retinopathy screening in a national programme: an economic analysis modelling study. *Lancet Digit Heal* [Internet]. 2020 May;2(5):e240-9. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S2589750020300601>
74. Tomić M, Vrabec R, Hendelja Đ, Kolarić V, Bulum T, Rahelić D. Diagnostic Accuracy of Hand-Held Fundus Camera and Artificial Intelligence in Diabetic Retinopathy Screening. *Biomedicines* [Internet]. 2023 Dec 22;12(1):34. Available from: <https://www.mdpi.com/2227-9059/12/1/34>
75. Sosale B, Sosale A, Murthy H, Sengupta S, Naveenam M. Medios- An offline, smartphone-based artificial intelligence algorithm for the diagnosis of diabetic retinopathy. *Indian J Ophthalmol* [Internet]. 2020;68(2):391. Available from: [https://journals.lww.com/ijo/Fulltext/2020/68020/Medios\\_\\_An\\_offline,\\_smartphone\\_based\\_artificial.30.aspx](https://journals.lww.com/ijo/Fulltext/2020/68020/Medios__An_offline,_smartphone_based_artificial.30.aspx)

76. Keel S, Lee PY, Scheetz J, Li Z, Kotowicz MA, MacIsaac RJ, et al. Feasibility and patient acceptability of a novel artificial intelligence-based screening model for diabetic retinopathy at endocrinology outpatient services: a pilot study. *Sci Rep [Internet]*. 2018 Mar 12;8(1):4330. Available from: <https://www.nature.com/articles/s41598-018-22612-2>
77. Ibáñez-bruron M c., Cruzat A, Órdenes-Cavieres G, Coria M. Exactitud de tamizaje de retinopatía diabética: inteligencia artificial versus tecnólogos médicos entrenados. *Rev Med Chil [Internet]*. 2021 Apr;149(4):493-500. Available from: [http://www.scielo.cl/scielo.php?script=sci\\_arttext&pid=S0034-98872021000400493&lng=en&rm=iso&tlang=en](http://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0034-98872021000400493&lng=en&rm=iso&tlang=en)
78. Wang R, Zuo G, Li K, Li W, Xuan Z, Han Y, et al. Systematic bibliometric and visualized analysis of research hotspots and trends on the application of artificial intelligence in diabetic retinopathy. *Front Endocrinol (Lausanne) [Internet]*. 2022 Oct 31;13. Available from: <https://www.frontiersin.org/journals/endocrinology/articles/10.3389/fendo.2022.1036426/full>
79. Morya AK, Gowdar J, Kaushal A, Makwana N, Biswas S, Raj P, et al. Evaluating the Viability of a Smartphone-Based Annotation Tool for Faster and Accurate Image Labelling for Artificial Intelligence in Diabetic Retinopathy. *Clin Ophthalmol [Internet]*. 2021 Mar;Volume 15:1023-39. Available from: <https://www.dovepress.com/evaluating-the-viability-of-a-smartphone-based-annotation-tool-for-fas-peer-reviewed-article-OPTH>
80. Jain A, Krishnan R, Rogye A, Natarajan S. Use of offline artificial intelligence in a smartphone-based fundus camera for community screening of diabetic retinopathy. *Indian J Ophthalmol [Internet]*. 2021;69(11):3150. Available from: [https://journals.lww.com/ijo/Fulltext/2021/11000/Use\\_of\\_offline\\_artificial\\_intelligence\\_in\\_a.40.aspx](https://journals.lww.com/ijo/Fulltext/2021/11000/Use_of_offline_artificial_intelligence_in_a.40.aspx)
81. Wang Y, Liu C, Hu W, Luo L, Shi D, Zhang J, et al. Economic evaluation for medical artificial intelligence: accuracy vs. cost-effectiveness in a diabetic retinopathy screening case. *npj Digit Med [Internet]*. 2024 Feb 21;7(1):43. Available from: <https://www.nature.com/articles/s41746-024-01032-9#citeas>
82. Arenas-Cavalli JT, Abarca I, Rojas-Contreras M, Bernuy F, Donoso R. Clinical validation of an artificial intelligence-based diabetic retinopathy screening tool for a national health system. *Eye [Internet]*. 2022 Jan 11;36(1):78-85. Available from: <https://www.nature.com/articles/s41433-020-01366-0>
83. Held LA, Wewetzer L, Steinhäuser J. Determinants of the implementation of an artificial intelligence-supported device for the screening of diabetic retinopathy in primary care - a qualitative study. *Health Informatics J [Internet]*. 2022 Jul 3;28(3):146045822211128. Available from: <http://journals.sagepub.com/doi/10.1177/14604582221112816>
84. Cao K. Artificial intelligence on diabetic retinopathy diagnosis: an automatic classification method based on grey level co-occurrence matrix and naive Bayesian model. *Int J Ophthalmol [Internet]*. 2019 Jul 18;12(7):1158-62. Available from: [http://www.ijo.cn/gjyken/ch/reader/view\\_abstract.aspx?file\\_no=20190717&flag=1](http://www.ijo.cn/gjyken/ch/reader/view_abstract.aspx?file_no=20190717&flag=1)
85. Sosale B, Aravind SR, Murthy H, Narayana S, Sharma U, Gowda SG V, et al. Simple, Mobile-based Artificial Intelligence Algo rithm in the detection of Diabetic Retinopathy (SMART) study. *BMJ Open Diabetes Res Care [Internet]*. 2020 Jan 28;8(1):e000892. Available from: <https://drc.bmj.com/lookup/doi/10.1136/bmjdrc-2019-000892>
86. Malerbi FK, Andrade RE, Morales PH, Stuchi JA, Lencione D, de Paulo JV, et al. Diabetic Retinopathy Screening Using Artificial Intelligence and Handheld Smartphone-Based Retinal Camera. *J Diabetes Sci Technol [Internet]*. 2022 May 12;16(3):716-23. Available from: <http://journals.sagepub.com/doi/10.1177/1932296820985567>

## FINANCIACIÓN

Los autores no recibieron financiación para el desarrollo de la presente investigación.

## CONFLICTO DE INTERESES

Los autores declaran que no existe conflicto de intereses.

## CONTRIBUCIÓN DE AUTORÍA

*Conceptualización:* Marck Julca, Richard Injante.

*Curación de datos:* Richard Injante.

*Análisis formal:* Marck A Julca, Richard Injante.

*Investigación:* Marck Julca, Richard Injante.

*Metodología:* Richard Injante.

*Administración del proyecto:* Marck Julca, Richard Injante.

*Recursos:* Richard Injante.

*Supervisión:* Richard Injante.

*Validación:* Richard Injante.

*Visualización:* Marck Julca.

*Redacción - borrador original:* Marck Julca, Richard Injante.

*Redacción - revisión y edición:* Marck Julca, Richard Injante.