



ACESSO ABERTO

Data de Recebimento:

10/06/2026

Data de Aceite:

18/05/2026

Data de Publicação:

22/06/2026

**Autor correspondente:*

Paulo Thiago Gomes da Silva,
graduando em Medicina
(UNICAP) e mestrando no
Programa de Pós-Graduação em
Saúde da Comunicação Humana
(UFPE). Rua do Príncipe, 526
– Boa Vista, Recife – PE, CEP
50050-900.
Telefone: (81) 99492-1988
E-mail: paulotgsilva@gmail.com

Citação:

SILVA, P.T.G; Inteligência
artificial como ferramenta
auxiliar no diagnóstico da
retinopatia diabética por meio
da análise de imagens de fundo
de olho.

Revista Multidisciplinar em
Saúde, v. 7, n. 2, 2026. [https://
doi.org/10.51161/integrar/
rem/4883](https://doi.org/10.51161/integrar/rem/4883)

DOI: 10.51161/integrar/
rem/4883

Editora Integrar© 2026.
Todos os direitos reservados.

INTELIGÊNCIA ARTIFICIAL COMO FERRAMENTA AUXILIAR NO DIAGNÓSTICO DA RETINOPATIA DIABÉTICA POR MEIO DA ANÁLISE DE IMAGENS DE FUNDO DE OLHO

Paulo Thiago Gomes da Silva^{a,b}, Rogério Luiz dos Santos Freitas^b, Júlia Aquino de Oliveira Sales^b, Paulo Matheus Gomes da Silva^c, Thiago Gomes Maciel de Lira^b, Maria Isabel Andrade Lima^b, Beatriz Freitas Seabra^b, Anthony José da Cunha Carneiro Lins^b.

^a Programa de Pós-Graduação em Saúde da Comunicação Humana, Universidade Federal de Pernambuco (UFPE). Av. Prof. Moraes Rego, 1235 – Cidade Universitária, Recife – PE, CEP 50670-901.

^b Escola de Comunicação e Ciências da Vida, Universidade Católica de Pernambuco (UNICAP). Rua do Príncipe, 526 – Boa Vista, Recife – PE, CEP 50050-900.

^c Centro de Ciências Médicas, Universidade Federal de Pernambuco (UFPE). Av. Prof. Moraes Rego, 1235 – Cidade Universitária, Recife – PE, CEP 50670-901.

RESUMO

Introdução: A retinopatia diabética (RD) é uma complicação microvascular do diabetes mellitus que pode evoluir silenciosamente até estágios avançados, com risco de perda visual irreversível. A inteligência artificial tem sido investigada como ferramenta auxiliar para ampliar o rastreamento e apoiar a análise de imagens de fundo de olho. **Objetivo:** Este estudo teve como objetivo analisar o uso da inteligência artificial como ferramenta auxiliar no rastreamento, na detecção e na classificação da retinopatia diabética por meio da análise de imagens de fundo de olho. **Metodologia:** Trata-se de uma revisão integrativa da literatura, realizada na base PubMed, em junho de 2026, com estudos publicados entre 2021 e 2026, em língua inglesa e disponíveis em texto completo gratuito. Após aplicação dos critérios de inclusão e exclusão, 13 artigos foram incluídos na análise final. **Resultados:** Os artigos analisados indicaram desempenho promissor dos sistemas de IA na triagem, detecção e classificação da RD, com destaque para sensibilidade, graduação da gravidade, identificação de lesões e uso associado a câmeras não midriáticas ou portáteis. Observou-se, entretanto, variação de desempenho conforme algoritmo, equipamento, qualidade da imagem e contexto de aplicação. **Conclusões:** A IA apresenta potencial para apoiar o rastreamento da RD e a priorização de encaminhamentos oftalmológicos. Sua incorporação à prática clínica, contudo, requer validação externa, integração aos fluxos assistenciais e avaliação em cenários reais.

Palavras-chave: Retinopatia Diabética; Inteligência Artificial; Aprendizado Profundo; Programas de Rastreamento; Telemedicina.

ABSTRACT

Introduction: Diabetic retinopathy is a microvascular complication of diabetes mellitus that may progress silently to advanced stages, with risk of irreversible visual loss. Artificial intelligence has been investigated as an auxiliary tool to expand screening and support the analysis of fundus images. Objective: This study aimed to analyze the use of artificial intelligence as an auxiliary tool in the screening, detection, and classification of diabetic retinopathy through the analysis of fundus images. Methodology: This is an integrative literature review conducted in PubMed in June 2026, including studies published between 2021 and 2026, written in English and available as free full text. After applying the inclusion and exclusion criteria, 13 articles were included in the final analysis. Results: The analyzed articles indicated promising performance of AI systems in the screening, detection, and classification of diabetic retinopathy, particularly regarding sensitivity, severity grading, lesion identification, and use with non-mydratic or handheld cameras. However, performance varied according to the algorithm, imaging device, image quality, and application context. Conclusions: AI shows potential to support diabetic retinopathy screening and the prioritization of ophthalmological referrals. Its incorporation into clinical practice, however, requires external validation, integration into healthcare workflows, and evaluation in real-world settings.

Keywords: Diabetic Retinopathy; Artificial Intelligence; Deep Learning; Mass Screening; Telemedicine.

INTRODUÇÃO

O diabetes mellitus (DM) está entre as doenças crônicas de maior impacto em saúde pública, por se tratar de uma condição progressiva, frequentemente silenciosa e associada a complicações sistêmicas relevantes. Entre suas complicações microvasculares, a retinopatia diabética (RD) ocupa posição de destaque pelo potencial de comprometer progressivamente a visão. A doença pode evoluir sem sintomas nos estágios iniciais, dificultando sua identificação precoce e reforçando a necessidade de avaliação periódica. Quando não diagnosticada e tratada em tempo oportuno, pode estar associada a edema macular diabético, hemorragias retinianas, neovascularização e formas proliferativas, com risco de perda visual significativa (Casarin et al., 2022; Franco et al., 2022).

A avaliação do fundo de olho desempenha papel central na identificação de alterações retinianas associadas ao diabetes, permitindo reconhecer sinais compatíveis com a RD e subsidiar a conduta clínica. No entanto, o acesso regular à avaliação oftalmológica representa um desafio em muitos sistemas de saúde, inclusive no SUS, onde limitações na oferta de programas estruturados e a demora para consultas especializadas prolongam o intervalo até a realização dos exames. A retinografia colorida consolida-se, nesse cenário, como alternativa relevante para ampliar o rastreamento, com aplicação em atenção primária, telemedicina e campanhas de saúde, favorecendo modelos mais acessíveis e escaláveis de detecção precoce (Bortoli et al., 2022).

O avanço da inteligência artificial (IA), especialmente dos modelos de deep learning (DL), ampliou as possibilidades de análise automatizada de imagens médicas. Na oftalmologia, sistemas baseados em IA têm sido desenvolvidos para detectar a presença da RD, classificar sua gravidade, reconhecer lesões retinianas, avaliar a qualidade das imagens e priorizar casos para encaminhamento especializado. Estudos recentes avaliaram sistemas autônomos e algoritmos aplicados a câmeras não midriáticas e portáteis em cenários clínicos reais, com resultados promissores para triagem em ambientes não especializados (Dai et al., 2021; Ipp et al., 2021; Kubin et al., 2024; Doğan et al., 2024).

Embora a IA represente uma estratégia promissora para ampliar o rastreamento e reduzir a carga dos especialistas, seu desempenho varia conforme o algoritmo, o equipamento de captura, a qualidade da imagem, a população avaliada e o protocolo de validação. Esses fatores reforçam a necessidade de

validação externa e avaliação em condições reais antes da implementação clínica ampla (Kubin et al., 2024; Doğan et al., 2024).

O presente trabalho tem como objetivo realizar uma revisão integrativa da literatura sobre o uso da IA como ferramenta auxiliar no rastreamento, na detecção e na classificação da retinopatia diabética por meio da análise de imagens de fundo de olho, com ênfase em estudos de 2021 a 2026. Especificamente, busca-se identificar os principais métodos e sistemas utilizados, os tipos de imagem e equipamentos empregados, os contextos de aplicação clínica e o desempenho dos modelos descritos nos estudos selecionados.

MATERIAIS E MÉTODOS

Trata-se de uma revisão integrativa da literatura, de abordagem qualitativa e caráter descritivo, voltada à análise de estudos sobre o uso da IA na triagem, detecção e classificação da retinopatia diabética por meio de imagens de fundo de olho.

Essa modalidade de revisão foi escolhida por permitir a síntese de evidências provenientes de diferentes desenhos metodológicos, favorecendo uma compreensão ampla do estado atual do conhecimento sobre o tema. O percurso contemplou: definição do tema e da questão norteadora; estabelecimento dos critérios de inclusão e exclusão; busca bibliográfica; triagem dos estudos por título e resumo; leitura completa dos artigos elegíveis; extração das informações relevantes; organização em tabela-síntese; e análise descritiva e comparativa dos resultados.

A questão norteadora da revisão foi: quais são as principais aplicações, métodos e desempenhos dos sistemas de inteligência artificial utilizados como ferramenta auxiliar no diagnóstico, triagem ou classificação da RD por meio de imagens de fundo de olho?

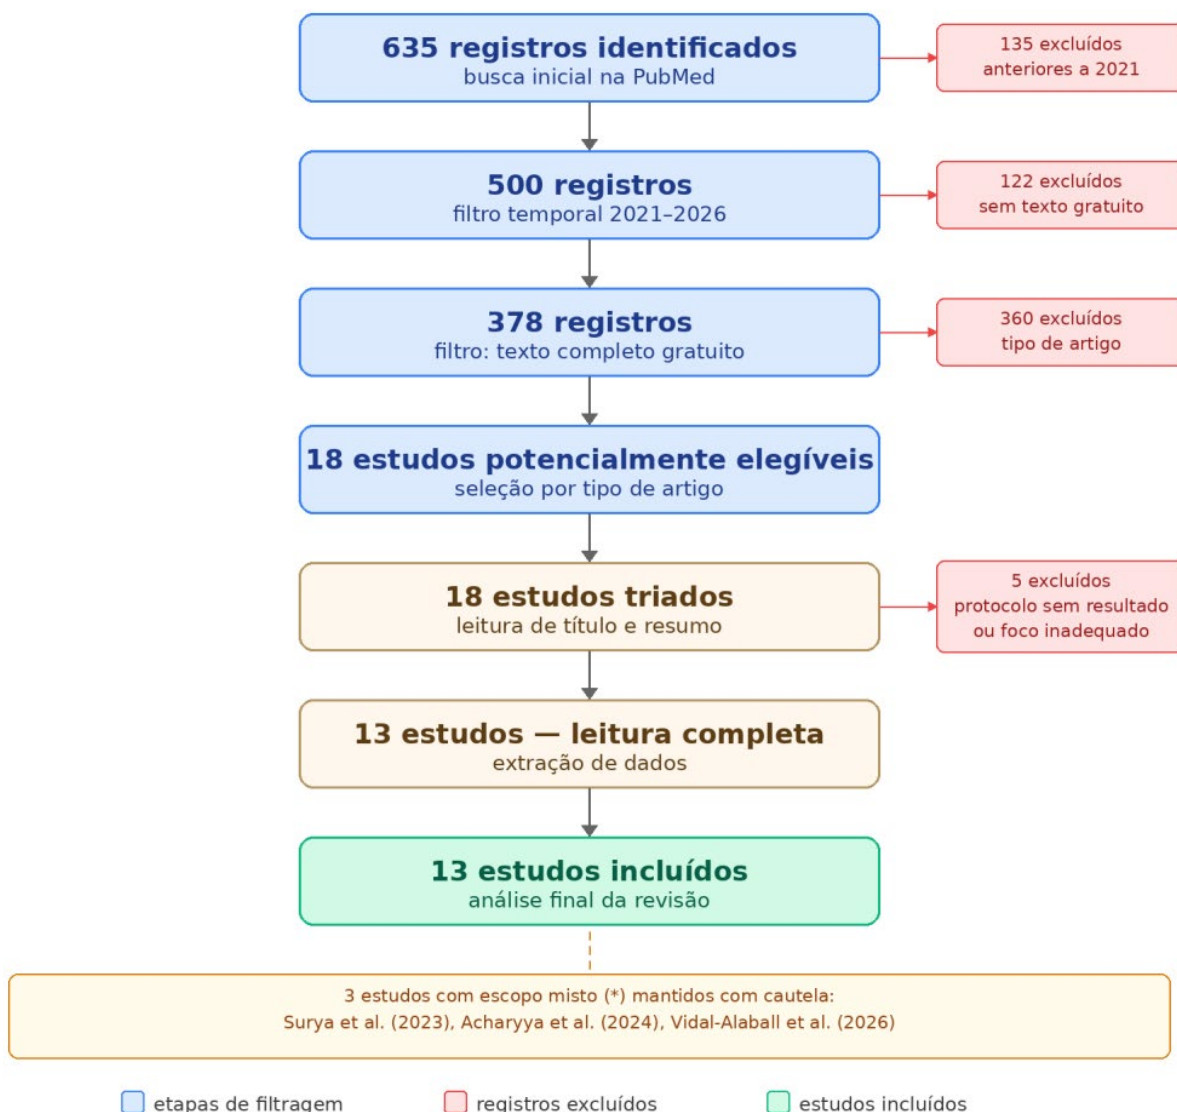
A busca bibliográfica foi realizada na base de dados PubMed, em junho de 2026, considerando estudos publicados entre 2021 e 2026, em língua inglesa e disponíveis em texto completo gratuito. Foram utilizados termos de busca em inglês, combinados por operadores booleanos, com restrição aos campos título e resumo. A estratégia de busca utilizada foi: ("diabetic retinopathy"[Title/Abstract]) AND ("artificial intelligence"[Title/Abstract] OR "machine learning"[Title/Abstract] OR "deep learning"[Title/Abstract]) AND ("fundus photography"[Title/Abstract] OR "fundus image"[Title/Abstract] OR "fundus images"[Title/Abstract] OR "retinography"[Title/Abstract] OR "retinal image"[Title/Abstract] OR "retinal images"[Title/Abstract]) AND ("screening"[Title/Abstract] OR "diagnosis"[Title/Abstract] OR "detection"[Title/Abstract])

Inicialmente, a busca identificou 635 resultados. Ao aplicar o filtro temporal de 2021 a 2026, foram encontrados 500 resultados. Em seguida, com a aplicação do filtro de texto completo gratuito, permaneceram 378 estudos. Para refinar a busca e priorizar estudos originais com maior aderência ao objetivo da revisão, foram selecionados os seguintes tipos de artigo na base PubMed: Clinical Study, Comparative Study, Evaluation Study, Observational Study e Validation Study. Após essa etapa, foram obtidos 18 estudos potencialmente elegíveis. A Figura 1 apresenta o fluxo de seleção dos estudos.

Foram adotados como critérios de inclusão: a) estudos originais publicados em língua inglesa; b) artigos disponíveis em texto completo gratuito; c) estudos publicados entre 2021 e 2026; d) pesquisas que abordassem retinopatia diabética como foco central ou como desfecho específico; e) estudos que utilizassem inteligência artificial, machine learning ou deep learning; f) pesquisas baseadas na análise de imagens de

fundo de olho, retinografia, fundus photography ou retinal images; g) estudos voltados à triagem, detecção, diagnóstico, classificação ou graduação da retinopatia diabética; e h) artigos que apresentassem métricas de desempenho, como sensibilidade, especificidade, acurácia, AUC, valor preditivo positivo, valor preditivo negativo ou concordância.

Figura 1 – Fluxo de seleção dos estudos incluídos na revisão



Fonte: Autores (2026).

Foram excluídos: a) artigos de revisão, revisões sistemáticas, metanálises, editoriais, cartas ao editor e comentários; b) protocolos de estudo sem apresentação de resultados; c) estudos sem foco direto em retinopatia diabética; d) artigos que não utilizassem imagens de fundo de olho ou retinografia; e) estudos voltados exclusivamente a outros exames, como tomografia de coerência óptica ou angiografia, quando desvinculados da análise de imagem de fundo de olho; f) pesquisas sem avaliação de desempenho do modelo de inteligência artificial; e g) estudos centrados apenas em segmentação de lesões isoladas, sem avaliação direta da triagem, detecção ou classificação global da retinopatia diabética.

Após a leitura dos títulos e resumos dos 18 estudos selecionados, cinco artigos foram excluídos por não atenderem plenamente aos critérios de inclusão. Dois deles foram excluídos por se tratarem de protocolos de estudo sem resultados; um por apresentar foco predominante na relação entre retinopatia

diabética e biomarcadores metabólicos; um por discutir predominantemente ajuste metodológico de métricas diagnósticas; e um por se concentrar na segmentação de exsudatos retinianos, sem avaliar diretamente a triagem ou o diagnóstico global da retinopatia diabética.

A amostra final foi composta por 13 artigos, selecionados após aplicação dos filtros, critérios de elegibilidade, triagem por título e resumo e leitura integral dos textos elegíveis. Estudos com escopo misto ou multidoença foram mantidos apenas quando apresentavam resultados específicos para RD obtidos a partir de imagens de fundo de olho: decisão justificada pelo fato de que alguns sistemas de IA avaliados na literatura recente são desenvolvidos para múltiplas alterações retinianas, mas apresentam métricas individualizadas para RD. Esses estudos foram incluídos na análise, porém interpretados com cautela.

Para a extração dos dados, os autores utilizaram uma tabela-síntese contemplando: autor e ano de publicação, tipo de estudo, população ou amostra, sistema ou algoritmo avaliado, tipo de imagem utilizada, principais métricas de desempenho, contexto de aplicação e limitações apontadas. A seleção dos estudos e a extração foram realizadas com base nos critérios previamente definidos.

A análise foi descritiva e comparativa. Os artigos foram organizados em tabela-síntese, permitindo comparar os sistemas avaliados, os tipos de imagem, os contextos de aplicação e os principais indicadores de desempenho. A discussão foi estruturada em torno dos seguintes eixos: desempenho diagnóstico dos algoritmos, uso de câmeras não midriáticas e portáteis, validação em cenário real, classificação da gravidade da doença, detecção de lesões retinianas, variabilidade entre algoritmos e equipamentos, e limitações para implementação clínica.

Por se tratar de uma revisão integrativa baseada exclusivamente em artigos científicos disponíveis em bases públicas, sem coleta de dados primários envolvendo seres humanos, não houve necessidade de submissão ao Comitê de Ética em Pesquisa.

Dentre as limitações metodológicas, destacam-se a utilização de apenas uma base de dados, a restrição a artigos em língua inglesa e a inclusão somente de estudos com texto completo gratuito, o que pode ter excluído pesquisas relevantes publicadas em periódicos de acesso restrito, introduzindo potencial viés de seleção. A consulta exclusiva à PubMed pode ter limitado a abrangência da busca, uma vez que estudos indexados em bases como EMBASE, Scopus, Web of Science, Cochrane Library ou LILACS podem não ter sido recuperados. A heterogeneidade entre os estudos quanto a algoritmos, populações, equipamentos, protocolos e métricas limita a comparação direta dos resultados, embora permita uma análise ampla das tendências recentes.

Por se tratar de uma revisão integrativa de caráter descritivo, não houve registro prévio de protocolo em plataforma pública nem aplicação de ferramenta formal de avaliação da qualidade metodológica ou risco de viés, como QUADAS-2, JBI ou STROBE, o que limita a análise crítica da robustez individual dos estudos incluídos.

RESULTADOS E DISCUSSÃO

Após a aplicação da estratégia de busca e dos critérios de elegibilidade, 18 estudos foram submetidos à triagem por título e resumo. Nessa etapa, cinco artigos foram excluídos: dois por se tratarem de protocolos sem resultados; um por foco predominante em biomarcadores metabólicos; um por discutir ajuste metodológico de métricas diagnósticas; e um por se concentrar exclusivamente na segmentação de

exsudatos retinianos, sem avaliação global da triagem ou do diagnóstico da doença.

Ao final, 13 artigos foram incluídos na análise. Os trabalhos selecionados abordaram sistemas de IA, predominantemente baseados em técnicas de deep learning, aplicados à triagem, detecção, classificação ou graduação da RD por meio de imagens de fundo de olho. A Tabela 1 apresenta os estudos com seus desenhos metodológicos, amostras, sistemas avaliados, tipos de imagem e principais resultados. Artigos com escopo misto ou multidoença foram mantidos quando apresentavam métricas específicas para retinopatia diabética, sendo interpretados com cautela na discussão.

Tabela 1 – Artigos incluídos na revisão

Autor/ano	Tipo de estudo/amostra	Sistema ou técnica	Imagem utilizada	Principais resultados
Ipp et al. (2021)	Estudo prospectivo, multicêntrico, transversal; 893 pacientes/1.786 olhos	EyeArt Automated DR Detection System	Retinografia colorida não midriática de dois campos	mtmDR: sens. 95,5%, espec. 85,0%; vtDR: sens. 95,1%, espec. 89,0%; imageability 97,4%
Dai et al. (2021)	Desenvolvimento e validação; treino com 466.247 imagens; validação local com 200.136 imagens	DeepDR; sistema multitarefa	Imagens centradas na mácula e disco óptico	AUCs 0,901–0,967 para lesões; 0,943–0,972 para estágios; AUC 0,973 para RD referenciável
Surya et al. (2023)*	Estudo prospectivo observacional; 1.085 pacientes	Dr Noon; CNN baseada em VGG	Fotografia não midriática, 45°	Sensibilidade 83,33%; especificidade 98,86%
Lupidi et al. (2023)	Estudo observacional transversal; 256 olhos, 251 incluídos	Optomed Aurora IQ com Selena+	Retinografia portátil não midriática, 50°	Sensibilidade 96,8%; especificidade 96,8%; kappa 0,935
Kubin et al. (2024)	Estudo prospectivo comparativo; 156 pacientes, 312 olhos, 624 imagens	21 algoritmos de IA comparados	Câmera portátil Optomed Aurora	Sens. média 77,5%; espec. média 80,6%; concordância 79,4%; grande variação entre algoritmos
Huhtinen et al. (2025)	Avaliação em mundo real; 156 participantes e 624 imagens	Aireen AI; EfficientNet V2	Câmera portátil Optomed Aurora	Sens. 94,8%; espec. 91,4%; acurácia 92,7%; NPV 96,6%
Doğan et al. (2024)	Estudo clínico comparativo; 900 recrutados, 865 elegíveis	EyeCheckup AI	Três câmeras: Canon CR2 AF, Topcon TRC-NW400 e Optomed Aurora	mtmDR: sens. 90,48%–95,65%, espec. 95,92%–97,21%; vtDR: sens. 95,12%–98,52%, espec. 95,93%–98,82%
Abreu-Gonzalez et al. (2025)	Estudo multicêntrico, transversal e observacional; 945 pacientes com diabetes	LuxIA	Imagem colorida única, 45°	Sens. 97,1%; espec. 94,8%; acurácia 95,2%; AUC 0,96; kappa 0,837
Similié et al. (2025)	Estudo de validação; 500 imagens retinianas de 6 campos	DL com pré-segmentação; U-Net/ Inception-v3	Retinografias de 6 campos	IA autônoma: sens. 78,4%, espec. 81,4%, kappa 0,72; NPV extrapolado 92,4%

Autor/ano	Tipo de estudo/amostra	Sistema ou técnica	Imagem utilizada	Principais resultados
Sedova et al. (2022)	Estudo piloto prospectivo; 54 pacientes/107 olhos	IDx-DR; sistema autônomo	Duas imagens coloridas 45° por olho; comparação com ultra-widefield	Sens. 100%, espec. 47% vs. 7F-mask; sens. 95%, espec. 47% vs. UWF full-field
Duggal et al. (2025)	Validação prospectiva e implementação; 250 na validação e 343 na implementação	Algoritmos comerciais de IA	Retinografia não midriática, dois campos, 45°	Implementação: sens. 99,6%, espec. 64,7%, PPV 87,4%, NPV 98,3%; RD referenciável: sens. 78,9%, espec. 98,1%
Acharyya et al. (2024)*	Estudo retrospectivo, transversal, duplo-cego; 2.261 imagens	Adven-i; IA baseada em DL e CNNs	Imagens de fundo de olho	RD vs. outras anormalidades: sens. 91,87%, espec. 85,12%, acurácia 88,61%, AUC 0,9404
Vidal-Alaball et al. (2026)*	Estudo observacional transversal; 1.652 olhos de 871 pacientes	UPRETINA; CNNs	Imagens não midriáticas de fundo de olho	RD: sens. 86,84%, espec. 95,64%, AUROC 0,9538, acurácia 95,03%

Fonte: Autores (2026).

Nota: os estudos marcados com (*) - Surya et al. (2023), Acharyya et al. (2024) e Vidal-Alaball et al. (2026) - apresentaram escopo misto ou multidoença. Foram mantidos na revisão por apresentarem métricas específicas para retinopatia diabética obtidas a partir de imagens de fundo de olho, sendo interpretados com cautela na discussão. Abreviações: sens. = sensibilidade; espec. = especificidade; AUC/AUROC = área sob a curva ROC; PPV/VPP = valor preditivo positivo; NPV/VPN = valor preditivo negativo; RD = retinopatia diabética; mtmDR = retinopatia diabética mais que leve; vtDR = retinopatia diabética ameaçadora à visão.

A produção científica incluída indica uma transição relevante: de modelos experimentais baseados em bases públicas padronizadas (como Kaggle-EyePACS, APTOS, Messidor-2 e IDRiD) para sistemas testados em contextos clínicos reais. A literatura mais recente reúne maior número de estudos multicêntricos, validações prospectivas, uso de câmeras não midriáticas e avaliações de desempenho em ambientes de triagem real.

Entre os achados mais expressivos está a elevada sensibilidade dos sistemas para detecção de formas referenciáveis ou ameaçadoras à visão. O EyeArt, avaliado por Ipp et al. (2021) em 893 pacientes e 1.786 olhos, alcançou sensibilidade de 95,5% para retinopatia diabética mais que leve e de 95,1% para a forma ameaçadora à visão. Esses resultados sugerem potencial para o uso da triagem autônoma em ambientes não especializados.

A capacidade de ir além da classificação binária representa outro avanço relevante. Dai et al. (2021) desenvolveram o DeepDR, sistema multitarefa que avalia a qualidade da imagem, detecta microaneurismas, exsudatos duros, manchas algodinosas e hemorragias, e classifica a RD em diferentes estágios, do inicial ao proliferativo. Essa abordagem pode ampliar a utilidade clínica dos algoritmos, aproximando-os do raciocínio utilizado por especialistas na análise da retinografia.

O crescimento no uso de câmeras portáteis e não midriáticas foi outro aspecto evidente nos estudos

revisados. Lupidi et al. (2023), Kubin et al. (2024), Huhtinen et al. (2025) e Doğan et al. (2024) avaliaram o uso da Optomed Aurora associada a sistemas de IA, apontando potencial para ampliar o rastreamento em cenários reais. Esses achados sugerem que há viabilidade de expandir a triagem para atenção primária, ambulatórios de endocrinologia, áreas rurais e localidades com menor disponibilidade de oftalmologistas.

O desempenho dos sistemas, porém, não é uniforme. Kubin et al. (2024), ao compararem 21 algoritmos aplicados a imagens obtidas com câmera portátil, observaram sensibilidade média de 77,5% e especificidade média de 80,6%, com ampla variação entre os modelos. Esse resultado indica que os achados de um sistema não devem ser generalizados para outros sem validação externa em condições reais.

De forma convergente, Similié et al. (2025), utilizando modelo de deep learning com pré-segmentação baseado em U-Net/Inception-v3, obtiveram sensibilidade de 78,4% e especificidade de 81,4% em 500 imagens retinianas de seis campos, com valor preditivo negativo extrapolado de 92,4%.

A influência do equipamento também foi observada por Doğan et al. (2024), que compararam três câmeras não midriáticas associadas ao EyeCheckup AI, e por Abreu-Gonzalez et al. (2025), na validação do LuxIA, com desempenho superior em imagens Topcon em comparação com a pequena amostra obtida por câmeras ZEISS. Em conjunto, esses achados indicam que a acurácia dos sistemas de IA depende não apenas do algoritmo, mas também da qualidade da imagem, do equipamento utilizado, do protocolo de captura e do contexto clínico de aplicação.

A avaliação em cenário real revelou desafios que transcendem a acurácia diagnóstica. Duggal et al. (2025), ao analisarem a implementação de IA em saúde pública, constataram alto desempenho para detecção de RD, mas identificaram obstáculos relacionados à qualidade da imagem, à integração com o fluxo assistencial e à adesão dos pacientes ao encaminhamento oftalmológico. A IA pode contribuir para o aprimoramento da triagem, mas não resolve, isoladamente, fragilidades estruturais dos sistemas de saúde.

A interpretação dos resultados exige atenção às limitações metodológicas dos próprios estudos incluídos. Em modelos de IA aplicados a imagens médicas, há risco de superestimação do desempenho quando os algoritmos são treinados e testados em bases controladas ou pouco representativas da prática clínica. Kubin et al. (2024) ilustraram esse ponto ao demonstrar ampla variação entre 21 algoritmos avaliados numa mesma base de imagens. Sedova et al. (2022) contribuíram com amostra reduzida (54 pacientes e 107 olhos), o que restringe a força de generalização dos achados. Abreu-Gonzalez et al. (2025) evidenciaram variação de desempenho dependente do equipamento.

Em conjunto, esses achados indicam que, embora sensibilidade, especificidade e AUC sejam indicadores essenciais, a aplicabilidade clínica dos sistemas depende de validação externa, padronização dos protocolos de captura, avaliação da qualidade da imagem e monitoramento dos desfechos após a triagem.

Surya et al. (2023), Acharyya et al. (2024) e Vidal-Alaball et al. (2026) foram incluídos com ressalva por avaliarem sistemas voltados a glaucoma, outras anormalidades retinianas ou múltiplas patologias. Sua inclusão na amostra foi mantida em razão das métricas específicas para RD apresentadas nesses estudos, contribuindo para a compreensão de sistemas multidoença na análise de retinografias, desde que interpretados com a cautela explicitada nos critérios metodológicos.

De modo geral, os artigos sinalizam que sistemas de IA podem reduzir a carga de trabalho dos oftalmologistas, ampliar a cobertura do rastreamento, acelerar a identificação de casos suspeitos e priorizar pacientes de maior risco. Entre as limitações recorrentes, destacam-se a heterogeneidade entre bases de dados, as diferenças entre equipamentos, a variação de desempenho entre algoritmos, a necessidade de

validação externa, a ocorrência de imagens não classificáveis e o risco de resultados falso-positivos ou falso-negativos. Vale ressaltar que os fatores limitantes não invalidam o potencial da tecnologia, mas condicionam sua adoção a critérios rigorosos.

A IA deve ser compreendida como recurso estratégico de apoio à triagem e à tomada de decisão, e não como substituta da avaliação oftalmológica. Sua adoção clínica requer validação rigorosa, fluxos de encaminhamento bem definidos, treinamento dos operadores e integração efetiva aos serviços de saúde.

CONCLUSÃO

Esta revisão analisou 13 estudos recentes sobre o uso da IA no diagnóstico, na triagem e na classificação da retinopatia diabética por imagens de fundo de olho. Os achados apontam desempenho promissor desses sistemas, especialmente na detecção da RD, na identificação de formas referenciáveis ou ameaçadoras à visão, na graduação da gravidade, na avaliação da qualidade da imagem e no reconhecimento de lesões retinianas específicas. A literatura analisada sugere que a IA pode contribuir para ampliar o rastreamento e apoiar a priorização de encaminhamentos oftalmológicos, sobretudo em contextos que utilizam câmeras não midriáticas, dispositivos portáteis e fluxos de triagem em ambientes não especializados. Entretanto, o desempenho dos algoritmos varia conforme o sistema utilizado, a população avaliada, a qualidade das imagens, o equipamento de captura e o padrão de referência adotado. Conclui-se que a IA representa uma ferramenta promissora de apoio à triagem e à decisão clínica na retinopatia diabética, sem substituir a avaliação oftalmológica. Sua incorporação à prática assistencial requer validação externa, padronização dos protocolos de captura, integração aos serviços de saúde, avaliação de custo-efetividade e acompanhamento dos desfechos clínicos em cenários reais.

CONFLITOS DE INTERESSE

Não há conflito de interesse.

REFERÊNCIAS

- ABREU-GONZALEZ, R. et al. Validation of artificial intelligence algorithm LuxIA for screening of diabetic retinopathy from a single 45° retinal colour fundus images: the CARDS study. **BMJ Open Ophthalmology**, v. 10, n. 1, e002109, 2025. DOI: 10.1136/bmjophth-2024-002109.
- ACHARYYA, M.; MOHARANA, B.; JAIN, S.; TANDON, M. A double-blinded study for quantifiable assessment of the diagnostic accuracy of AI tool "ADVEN-i" in identifying diseased fundus images including diabetic retinopathy on a retrospective data. **Indian Journal of Ophthalmology**, v. 72, Suppl. 1, p. S46-S52, 2024. DOI: 10.4103/IJO.IJO_3342_22.
- BORTOLI, Julia Quadri et al. Retinografia como forma de rastreio de retinopatia diabética em hospital terciário do Sistema Único de Saúde. **Revista Brasileira de Oftalmologia, Rio de Janeiro**, v. 81, e0057, 2022. DOI: 10.37039/1982.8551.20220057.
- CASARIN, Daniele Escudeiro et al. Diabetes mellitus: causas, tratamento e prevenção. **Brazilian Journal of Development**, v. 8, n. 2, p. 10062-10075, 2022. DOI: 10.34117/bjdv8n2-010.
- DAI, Ling et al. A deep learning system for detecting diabetic retinopathy across the disease spectrum. **Nature Communications**, v. 12, p. 3242, 2021. DOI: 10.1038/s41467-021-23458-5.

DOĞAN, Mehmet Erkan et al. Head to head comparison of diagnostic performance of three non-mydratric cameras for diabetic retinopathy screening with artificial intelligence. **Eye**, v. 38, p. 1694-1701, 2024. DOI: 10.1038/s41433-024-03000-9.

DUGGAL, Mona et al. Real-World Evaluation of AI-Driven Diabetic Retinopathy Screening in Public Health Settings: Validation and Implementation Study. **JMIR Medical Informatics**, v. 13, n. 1, e67529, 2025. DOI: 10.2196/67529.

FRANCO, Elisa Marques et al. Revisão bibliográfica: retinopatia diabética. **Brazilian Journal of Development**, p. 35257-35264, 2022. DOI: 10.34117/bjdv8n3-285.

HUHTINEN, Petri et al. Real-World Evaluation of Artificial Intelligence-Based Diabetic Retinopathy Screening Using the Optomed Aurora Handheld Fundus Camera. **Diabetes Technology & Therapeutics**, v. 27, n. 12, p. 1023-1025, 2025. DOI: 10.1177/15209156251369886.

IPP, Eli et al. Pivotal Evaluation of an Artificial Intelligence System for Autonomous Detection of Referrable and Vision-Threatening Diabetic Retinopathy. **JAMA Network Open**, v. 4, n. 11, e2134254, 2021. DOI: 10.1001/jamanetworkopen.2021.34254.

KUBIN, Anna-Maria et al. Comparison of 21 artificial intelligence algorithms in automated diabetic retinopathy screening using handheld fundus camera. **Annals of Medicine**, v. 56, n. 1, 2352018, 2024. DOI: 10.1080/07853890.2024.2352018.

LUPIDI, Marco et al. Artificial intelligence in diabetic retinopathy screening: clinical assessment using handheld fundus camera in a real-life setting. **Acta Diabetologica**, v. 60, p. 1083-1088, 2023. DOI: 10.1007/s00592-023-02104-0.

SEDOVA, A. et al. Comparison of early diabetic retinopathy staging in asymptomatic patients between autonomous AI-based screening and human-graded ultra-widefield colour fundus images. **Eye**, v. 36, p. 510-516, 2022. DOI: 10.1038/s41433-021-01912-4.

SIMILIÉ, Dyllan Edson et al. Grading of diabetic retinopathy using a pre-segmenting deep learning classification model: Validation of an automated algorithm. **Acta Ophthalmologica**, v. 103, n. 2, p. 215-221, 2025. DOI: 10.1111/aos.16781.

SURYA, Janani et al. Efficacy of deep learning-based artificial intelligence models in screening and referring patients with diabetic retinopathy and glaucoma. **Indian Journal of Ophthalmology**, v. 71, n. 10, p. 3225-3233, 2023. DOI: 10.4103/IJO.IJO_2225_22.

VIDAL-ALABALL, Josep et al. Clinical validation of artificial intelligence algorithms for the detection of different central-involved retinal pathologies and glaucoma from non-mydratric images. **Frontiers in Artificial Intelligence**, v. 9, 1754682, 2026. DOI: 10.3389/frai.2026.1754682.