

Oftalmologia e Otorrinolaringologia

Capítulo 23

Edição IX

DIAGNÓSTICO PRECOCE DE RETINOPATIAS POR MEIO DE ALGORITMOS DE INTELIGÊNCIA ARTIFICIAL

JULIA BASOLLI GOMIERO¹
LUIZA BRONSARTO MOTTA¹
PEDRO LUIZ MARQUES CANCIANI¹

1. Discente - Centro Universitário FMABC

Palavras-chave: Retinopatias; Rastreamento; Inteligência Artificial.

DOI

10.59290/1761702090

EP EDITORA
PASTEUR

INTRODUÇÃO

A retina é um dos tecidos mais metabolicamente ativos e especializados do organismo. Sua elevada demanda energética, organização neurovascular complexa e limitada capacidade regenerativa tornam-na particularmente vulnerável a distúrbios homeostáticos, o que contribui para que as doenças da retina figurem entre as principais causas de comprometimento visual e cegueira em todo o mundo (AKIL *et al.*, 2021; WANG *et al.*, 2025).

Segundo a Organização Mundial da Saúde (2026), estima-se que 2,2 bilhões de pessoas apresentem algum grau de déficit visual para perto ou para longe. Entre os casos que poderiam ter sido prevenidos ou que ainda não foram adequadamente tratados, aproximadamente 11,9 milhões são atribuídos a doenças da retina: 8 milhões à degeneração macular relacionada à idade (DMRI) e 3,9 milhões à retinopatia diabética (RD).

Além da RD e da DMRI, este capítulo aborda outras condições de elevada relevância clínica: a retinopatia da prematuridade (ROP), a oclusão venosa da retina (OVR) e o descolamento de retina. A RD decorre de alterações funcionais e estruturais da microcirculação retiniana secundárias à hiperglicemia crônica. A ROP é uma doença vasoproliferativa da retina imatura, caracterizada pela interrupção do desenvolvimento vascular fisiológico e consequente neovascularização por hipóxia. A OVR resulta da obstrução do fluxo venoso retiniano, com edema, hemorragia e graus variáveis de isquemia; já a DMRI envolve a degeneração de componentes da retina externa e da coróide; e o descolamento de retina corresponde à separação da retina neurosensorial do epitélio pigmentar (AKIL *et al.*, 2021; PARMAR *et al.*, 2024).

O impacto dessas condições não decorre apenas de sua frequência, mas também da dissociação temporal entre o início da lesão e a percepção dos sintomas. Alterações retinianas podem progredir enquanto a acuidade visual permanece relativamente preservada e, quando a perda visual se torna evidente, parte do dano estrutural pode já ser irreversível. Por essa razão, a identificação precoce constitui etapa fundamental para a preservação da função visual (HAILU *et al.*, 2026; WINEBRAKE & LIM, 2026).

Entre os métodos empregados para essa finalidade, destacam-se a retinografia e a tomografia de coerência óptica (OCT). Em comparação com modalidades mais especializadas, esses exames apresentam menor custo relativo, aquisição pouco invasiva e informações complementares entre si, o que favorece sua utilização no diagnóstico precoce e no acompanhamento longitudinal (AKIL *et al.*, 2021; DI GIAMMARCO *et al.*, 2025).

Entretanto, a disponibilidade desses métodos não assegura, isoladamente, o acesso oportuno ao rastreio. Seu uso depende de equipamentos adequados, imagens de qualidade, profissionais capacitados e fluxos de encaminhamento estruturados. Em muitos sistemas de saúde, a demanda supera a disponibilidade de especialistas, enquanto os custos, as desigualdades de acesso e a variabilidade na aquisição e interpretação das imagens dificultam a assistência (SAVASTANO *et al.*, 2025; BERRADA *et al.*, 2026).

Nesse contexto, a inteligência artificial (IA) tem sido investigada como ferramenta de apoio ao diagnóstico precoce das doenças da retina. Suas aplicações incluem detecção de alterações, classificação de gravidade e predição de progressão (DI GIAMMARCO *et al.*, 2025; AKIL *et al.*, 2021). A natureza digital e repro-

duto da retinografia e da OCT favorece a exploração desse campo tecnológico (AUNG *et al.*, 2021).

Este capítulo tem como objetivo sintetizar criticamente as evidências sobre a aplicação da IA ao diagnóstico precoce da RD, ROP, OVR, DMRI e do descolamento de retina, com ênfase em sistemas baseados em retinografia e OCT. Também serão discutidos o desempenho desses modelos, suas possibilidades de incorporação à prática clínica e os principais desafios metodológicos, técnicos e éticos relacionados à sua utilização em larga escala.

MÉTODO

Este capítulo consiste em uma revisão narrativa da literatura, conduzida entre junho e julho de 2026, sobre o uso da IA na detecção precoce de retinopatias e outras doenças retinianas. A análise priorizou sistemas aplicados a imagens de fundo de olho e exames de OCT, modalidades amplamente utilizadas no rastreamento e na avaliação precoce de alterações retinianas. Foram abordadas a retinopatia diabética, a retinopatia da prematuridade, a oclusão venosa retiniana, a degeneração macular relacionada à idade e o descolamento de retina.

A busca foi realizada nas bases PubMed/MEDLINE, Scopus e Google Scholar, utilizando combinações dos descritores: “*Artificial Intelligence*”, “*Machine Learning*”, “*Deep Learning*”, “*Convolutional Neural Networks*”, “*Computer-Aided Diagnosis*”, “*Ophthalmology*”, “*Retinopathy*”, “*Retinal Diseases*”, “*Diabetic Retinopathy*”, “*Retinopathy of Prematurity*”, “*Retinal Vein Occlusion*”, “*Age-Related Macular Degeneration*”, “*Retinal Detachment*”, “*Fundus Photography*” e “*Optical Coherence Tomography*.” Os termos foram combinados por operadores booleanos e adaptados às características de cada base de dados.

Buscas complementares foram realizadas com os descritores “*Healthcare*”, “*Medicine*”, “*Medical Imaging*”, “*Clinical Decision Support*” e “*Precision Medicine*” para fundamentar os aspectos conceituais e as aplicações da IA em saúde.

Foram incluídas publicações em inglês, entre 2014 e 2026, disponíveis em texto completo e relacionadas ao escopo do capítulo. Foram considerados revisões, estudos de acurácia diagnóstica, estudos de desenvolvimento, validação e implementação de algoritmos; além de diretrizes, consensos, documentos institucionais e capítulos de livros.

Após a seleção, 30 publicações foram incluídas na síntese qualitativa. Nos estudos de rastreamento, foram analisadas, quando disponíveis, a condição retiniana investigada, a modalidade de imagem, a abordagem algorítmica, a tarefa clínica, a estratégia de validação, as medidas de desempenho (incluindo sensibilidade, especificidade, área sob a curva AUC/ROC, escore F1 e acurácia) e as principais limitações. Os achados foram sintetizados de forma descritiva e organizados em quatro eixos temáticos: fundamentos da IA aplicada; utilização da IA nas principais doenças da retina; limitações e desafios para sua implementação clínica; e perspectivas futuras.

RESULTADOS E DISCUSSÃO

Fundamentos da inteligência artificial aplicada

A oftalmologia é uma área particularmente oportuna à aplicação da IA, dado que os exames de imagem constituem parte fundamental do processo diagnóstico, configurando uma ampla base de dados digital, padronizável e reproduzível, especialmente em relação à retina (SAVASTANO *et al.*, 2025; PARMAR *et al.*,

2024). Como, em estágios iniciais, muitas das doenças desse tecido são oligossintomáticas, mapear por meio da IA alterações estruturais e vasculares precoces pode configurar uma importante janela de oportunidade para intervenção (WINEBRAKE & LIM, 2026).

A IA corresponde a um campo amplo da ciência da computação dedicado ao desenvolvimento de sistemas capazes de executar tarefas como reconhecimento de padrões, classificação, predição e apoio à tomada de decisão (AUNG *et al.*, 2021). Suas aplicações clínicas atuais referem-se predominantemente a um subtipo conhecido como IA de propósito específico, cujos sistemas são desenvolvidos para tarefas predeterminadas. Nesse sentido, Berrada *et al.* (2026) ressalta que o desempenho desses modelos deve ser sempre interpretado conforme sua finalidade, os dados empregados no desenvolvimento e o contexto clínico de aplicação.

No campo do diagnóstico precoce das doenças da retina, grande parte dessas aplicações é organizada em sistemas diagnóstico assistido por computador (CAD), destinados a apoiar a interpretação dos exames e a tomada de decisão clínica (AKIL *et al.*, 2021). Em tarefas específicas, alguns modelos alcançaram desempenho comparável ou superior ao de especialistas, embora ainda sejam pouco avaliados em condições de vida real.

Para compreender os diferentes modelos diagnósticos de IA, é útil considerar os seguintes componentes: a base de dados fornecida; a arquitetura computacional e as estratégias de aprendizado, que definem como essas informações são processadas; a tarefa para a qual o modelo foi criado; e sua avaliação de desempenho (ALZUBAIDI *et al.*, 2021; WINEBRAKE & LIM, 2026).

Bases de dados

No estudo das doenças da retina, a retinografia e a OCT constituem as principais fontes de dados para o desenvolvimento de sistemas de IA. A retinografia fornece uma representação bidimensional do fundo ocular, permitindo documentar a mácula, o disco óptico, a vasculatura e as lesões visíveis. Por ser não invasiva, relativamente acessível e compatível com aquisição portátil e interpretação remota, representa uma das principais ferramentas utilizadas em programas de rastreamento (BERRADA *et al.*, 2026; SAVASTANO *et al.*, 2025). A OCT, por sua vez, produz imagens seccionais de alta resolução das camadas retinianas, permitindo identificar alterações microscópicas, como espessamento, acúmulo de fluido, atrofia e desorganização estrutural (PARMAR *et al.*, 2024). Hailu *et al.* (2026) destacam a complementaridade entre essas modalidades: enquanto a retinografia oferece uma visão mais ampla das alterações vasculares e morfológicas, a OCT fornece informações estruturais em profundidade.

Arquiteturas computacionais e estratégias de aprendizado

Grande parte dos sistemas CAD utilizados em Oftalmologia baseia-se em *Machine Learning* (ML), uma abordagem de IA na qual, em vez de receber regras explícitas para todas as situações possíveis, o modelo identifica e cruza padrões presentes nas bases de dados e os utiliza para estimar a resposta mais provável diante de um novo exame (WINEBRAKE & LIM, 2026).

Entre as estratégias de aprendizado do ML, o aprendizado supervisionado é predominante nos estudos de imagens retinianas. Nele, o algoritmo é treinado com exames previamente classificados por especialistas, e cada imagem recebe um rótulo, como “normal”, “doença referenciável” ou “imagem não graduável”. Nos

métodos convencionais de ML, o modelo pode utilizar parâmetros previamente estabelecidos, como calibre vascular ou espessura retiniana, para associar padrões visuais a essas categorias (Savastano *et al.*, 2025). Como esse processo depende de grandes bases de exemplos rotulados, estratégias de aprendizado não supervisionado, auto supervisionado e de *transfer learning* também têm sido estudadas para reduzir essa dependência (ALZUBAIDI *et al.*, 2021; AUNG *et al.*, 2021).

Já o *Deep Learning* (DL) é um subconjunto do ML que, além de estabelecer relações estatísticas entre os dados e os rótulos, permite que o próprio modelo aprenda automaticamente quais características são mais úteis para cada tarefa proposta (HAILU *et al.*, 2026). Para isso, o DL utiliza redes neurais artificiais organizadas em múltiplas camadas de processamento, nas quais as informações se conectam de diferentes formas e com diferentes pesos (SAVASTANO *et al.*, 2025).

Na análise de uma retinografia, por exemplo, as primeiras camadas podem reconhecer bordas e contrastes; as intermediárias combinam esses elementos em vasos e estruturas anatômicas; e as mais profundas identificam padrões associados a lesões ou categorias diagnósticas (ALZUBAIDI *et al.*, 2021; PARMAR *et al.*, 2024).

Entre as arquiteturas de DL, as *Convolutional Neural Networks* (CNNs) constituem a principal forma de análise automatizada de imagens retinianas. Seus filtros identificam padrões espaciais locais e os combinam progressivamente para executar diferentes tarefas: a classificação atribui o exame a uma categoria ou grau de gravidade; a detecção identifica a presença e a localização aproximada de lesões; e a segmentação delimita estruturas anatômicas ou regiões patológicas, permitindo sua quantificação

(AKIL *et al.*, 2021; SAVASTANO *et al.*, 2025).

Em retinografias e exames de OCT, métodos de inteligência artificial explicável, como o mapeamento de ativação de classe (CAM) podem destacar as áreas da imagem que mais contribuíram para a decisão do modelo. Dessa forma, permitem verificar se a classificação se baseou em estruturas ou alterações anatomicamente plausíveis, e não em artefatos ou padrões sem relação com a doença. Modelos generativos também têm sido investigados para reconstrução de imagens, redução de ruído e correção de artefatos, podendo aprimorar a qualidade dos dados utilizados na análise (DI GIAMMARCO *et al.*, 2025).

Avaliação de desempenho

O desenvolvimento e a avaliação de um modelo envolvem conjuntos distintos de treinamento, validação e teste. Durante o treinamento, o algoritmo ajusta seus parâmetros a partir dos exemplos disponíveis; o conjunto de validação orienta a otimização do modelo; e o conjunto de teste avalia seu desempenho em exames que não participaram das etapas anteriores. Após o desenvolvimento, a inferência corresponde à aplicação do sistema treinado a um novo exame.

Aung *et al.* (2021) descrevem o papel de bases de dados públicas no treinamento e na comparação de modelos destinados à segmentação vascular, à classificação de doenças e à detecção de alterações retinianas. Embora favoreçam a reprodutibilidade dos estudos, essas bases diferem quanto às populações incluídas, à qualidade e à variabilidade das imagens e aos critérios de rotulagem, o que limita a comparação direta entre modelos e sua generalização para cenários externos (ALZUBAIDI *et al.*, 2021).

Nos estudos diagnósticos, o desempenho é descrito principalmente por sensibilidade, especificidade, acurácia, precisão, área sob a curva ROC (AUC-ROC) e escore F1, este sintetizando precisão e sensibilidade em uma única medida (HAILU *et al.*, 2026; WINEBRAKE & LIM, 2026).

A interpretação dessas métricas deve considerar a finalidade do sistema, a prevalência da doença, a qualidade das imagens, o padrão de referência e as características da população estudada. Hailu *et al.* (2026) ressalta que, em programas de rastreamento, costuma-se priorizar elevada sensibilidade para reduzir a perda de casos potencialmente tratáveis, ainda que isso possa aumentar o número de falsos positivos.

Aplicações da IA nas doenças da retina

Retinopatia diabética (RD)

A RD é, entre as retinopatias, aquela em que a IA alcançou validação clínica mais robusta, servindo de referência para o desenvolvimento de sistemas em outras doenças oculares.

Gulshan *et al.* (2016) desenvolveram um algoritmo de aprendizado profundo para detecção de RD referível a partir de fotografias de fundo de olho, validado em dois conjuntos independentes: EyePACS-1 e Messidor-2. No ponto operacional de alta sensibilidade, o algoritmo atingiu sensibilidade de 97,5% e especificidade de 93,4% no EyePACS-1, e sensibilidade de 96,1% e especificidade de 93,9% no Messidor-2, com ROC de 0,991 e 0,990, respectivamente. Esses valores costumam ser citados como evidência de que o desempenho do modelo se equipara ao de oftalmologistas na gradação manual das mesmas imagens. Vale notar que imagens de qualidade insuficiente haviam sido previamente removidas por avaliadores humanos, de

modo que esses números refletem o desempenho do algoritmo num conjunto já filtrado, distinto do que se observa num programa de rastreamento de rotina.

O sistema de inteligência artificial SELENA (Singapore Eye Lesion Analyzer), foi inicialmente validado por Ting *et al.* (2017) como um modelo multitarefa capaz de identificar, a partir da mesma imagem de fundo de olho, RD referível, possível glaucoma e degeneração DMRI. Na base de validação primária, com 14.880 pacientes e 71.896 imagens, a ROC para RD referível foi de 0,936 (sensibilidade de 90,5%, especificidade de 91,6%); para a RD que ameaça a visão, a ROC atingiu 0,958 (sensibilidade de 100%, especificidade de 91,1%). A coorte de validação primária provém majoritariamente do programa nacional de rastreamento de Singapura; a multiétnica anunciada no título do estudo se sustenta com mais força nos dez conjuntos de dados secundários usados para validação externa do que na base principal (TING *et al.*, 2017).

O avanço regulatório mais significativo veio com o estudo de Abràmoff *et al.* (2018), que comparou um sistema autônomo de IA (IDx-DR, agora denominado *Luminetics Core*) à leitura de referência do *Wisconsin Fundus Photograph Reading Center* em 900 pacientes diabéticos sem diagnóstico prévio de RD, atendidos por operadores de atenção primária. O sistema alcançou sensibilidade de 87,2% e especificidade de 90,7%, obtidos num desenho experimental mais próximo da prática clínica real, com operadores leigos e pacientes não pré-selecionados. Esse resultado levou à primeira autorização da *Food and Drug Administration* (FDA) para um sistema diagnóstico autônomo de IA em qualquer especialidade médica (LIM *et al.*, 2024).

Após a aprovação do *Luminetics Core*, outros sistemas também obtiveram autorização regulatória para rastreamento autônomo da RD. O *EyeArt* (*Eyenuk*) recebeu autorização da FDA e na União Europeia. O *AEYE Diagnostic Screening* (*AEYE Health*) ampliou as possibilidades de implementação da IA ao permitir a realização do rastreamento utilizando câmeras portáteis. Em Singapura, o sistema *SELENA* foi incorporado ao programa nacional de rastreamento de RD, DMRI e Glaucoma (LIM *et al.*, 2024).

Paralelamente ao avanço regulatório, cresce o interesse em compreender o impacto econômico da incorporação desses sistemas. Modelagens econômicas sugerem que o rastreamento autônomo por IA realizado no ponto de atendimento pode prevenir um número maior de casos de perda visual grave quando comparado ao encaminhamento convencional para exame oftalmológico, além de reduzir custos relacionados ao tratamento de complicações tardias e aumentar os anos de vida ajustados pela qualidade. Embora a maior parte das aplicações atuais utilize fotografias coloridas do fundo de olho, estudos recentes indicam que algoritmos baseados em OCT também apresentam elevado desempenho no diagnóstico. Entretanto, o custo mais elevado dos equipamentos de OCT limita sua utilização como método de rastreamento populacional, mantendo a retinografia como a estratégia mais viável para programas de saúde pública (LIM *et al.*, 2024).

Degeneração macular relacionada à idade (DMRI)

Para a DMRI, o estudo de referência é o de Peng *et al.* (2019), que desenvolveram o *DeepSeeNet*, modelo de aprendizado profundo capaz de classificar automaticamente a gravidade da doença segundo a Escala de Gravidade Simplificada do *Age-Related Eye Disease Study*

(AREDS), a partir de fotografias coloridas de fundo de olho de ambos os olhos. O modelo reproduz a lógica empregada pelos especialistas ao avaliar separadamente dois dos principais fatores de risco para progressão da doença: drusas de grande tamanho e alterações pigmentares do epitélio pigmentar da retina em cada olho, combinando essas informações para gerar uma pontuação de gravidade em nível de paciente. Na validação utilizando o banco de dados do AREDS, o *DeepSeeNet* alcançou acurácia global de 67,1%, superando a média dos especialistas da retina (59,9%) na classificação da gravidade da DMRI.

A identificação de biomarcadores prognósticos em fotografias de fundo de olho e OCT, bem como a detecção automática de atrofia geográfica e de neovascularização macular são outras linhas de pesquisa presentes na literatura.

Apesar dos avanços observados, ainda não existe nenhum sistema de IA aprovado nos Estados Unidos ou na União Europeia para o diagnóstico autônomo da DMRI, diferentemente do que ocorreu na RD. No entanto, a doença já integra plataformas multitarefa, como o *SELENA*, previamente descrito, que realizam a detecção simultânea de múltiplas doenças retinianas a partir de uma única fotografia de fundo de olho (LIM *et al.*, 2024).

Retinopatia da prematuridade (ROP)

A ROP trata-se de uma doença pediátrica, dependente de rastreamento sistemático em unidades neonatais, cuja classificação está sujeita a variabilidade interobservador. As diferenças na disponibilidade de cuidados neonatais entre países de renda alta, média e baixa produzem perfis epidemiológicos distintos, e é justamente nos contextos de menor renda, em que o diagnóstico oportuno é mais escasso, que o potencial benefício da triagem assistida por IA é maior (SABRI *et al.*, 2022; LIM *et al.*, 2024).

O i-ROP-DL (*Imaging and Informatics in ROP – Deep Learning*) é um sistema que atribui a cada imagem uma pontuação de gravidade vascular (*vascular severity score*, VSS) numa escala de 1 a 9, alinhada à Classificação Internacional da ROP (ICROP), permitindo aumentar o diagnóstico da doença *plus* (LIM *et al.*, 2024). Maitra *et al.* (2024) citam ainda o uso de dados de populações indianas para construir modelos preditivos de risco de ROP com indicação de tratamento, e destacam que a IA tem funcionado também como ferramenta epidemiológica, evidenciando que unidades neonatais com menor capacidade de monitoramento e titulação de oxigênio apresentam maior gravidade de ROP entre seus pacientes.

Outras doenças da retina e da superfície ocular

RD, DMRI e ROP são as aplicações mais maduras da IA em oftalmologia, mas o campo já avançou além dessas três condições, estendendo-se sobretudo à oclusão da veia retiniana (OVR) e ao descolamento de retina (Costin, Fira & Goraş, 2025; Lim *et al.*, 2024).

Para a OVR, Nagasato *et al.* (2019) treinaram uma rede neural profunda para detectar áreas de não perfusão retiniana a partir de imagens de angiografia por OCT (OCTA), comparando seu desempenho a um classificador SVM. A rede atingiu ROC de 0,976, sensibilidade de 94% e especificidade de 97%, superando SVM. Um eixo complementar de pesquisa em OVR trata não da detecção, mas do valor prognóstico de biomarcadores de imagem: Waldstein *et al.* (2017) desenvolveram um algoritmo de aprendizado de máquina para segmentação totalmente automatizada da interface vítreo-macular em exames tridimensionais de OCT de 391 pacientes com oclusão venosa da retina. A abordagem permitiu caracterizar a

adesão vítreo-macular em larga escala e investigar sua associação com a resposta à terapia anti-VEGF, demonstrando o potencial da IA para a avaliação automatizada de biomarcadores em OCT, embora a associação observada inicialmente tenha perdido significância após o ajuste para a acuidade visual basal.

Já para o descolamento de retina, Ohsugi *et al.* (2017) apresentou uma rede de aprendizado profundo identificou descolamento de retina regmatogênico a partir de fotografias de fundo de olho de campo ultra-amplo, alcançando sensibilidade de 97,6%, especificidade de 96,5% e ROC de 0,988. Os próprios autores argumentam que esse tipo de sistema é especialmente relevante para regiões remotas sem acesso a serviços especializados, já que o desfecho do descolamento de retina depende diretamente da rapidez do diagnóstico.

Complementando as aplicações descritas anteriormente, Lim *et al.* (2024) revisam o uso da IA em outras afecções retinianas, incluindo suas aplicações para cirurgia vitreoretiniana, doenças vasculares da retina e retinopatia da anemia falciforme.

Perspectivas futuras

Otimização do fluxo de triagem e telemedicina

Embora o rastreamento da RD seja reconhecidamente eficaz na prevenção da perda visual, os recursos humanos e financeiros necessários para sustentar programas de triagem em larga escala permanecem insuficientes na maioria dos países (Vujosevic *et al.*, 2020). Nesse contexto, a integração entre a IA, telemedicina e dispositivos portáteis para aquisição de imagens têm transformado as estratégias diagnósticas, automatizando a detecção, classificação e o encaminhamento dos casos de RD, com potencial para aumentar a custo-efetividade dos programas de triagem (Huang *et al.*;2022).

Abordagens multimodais

A integração de múltiplas modalidades de dados, em vez de uma única fotografia de fundo de olho, num mesmo sistema de decisão é promissora. Vamsidhar *et al.* (2026), descrevem arquiteturas que combinam fotografia de fundo de olho, tomografia de coerência óptica, angiografia por OCT (OCTA) e metadados clínicos. Os autores relatam que essa integração melhora não apenas a detecção, mas também a gradação de RD, glaucoma e DMRI, além de favorecer o prognóstico dessas doenças: deslocando o foco do diagnóstico pontual para a predição de trajetórias clínicas.

Biomarcadores sistêmicos e oculômica

Além do diagnóstico de doenças oculares, as imagens da retina têm se consolidado como uma importante fonte de biomarcadores para a avaliação da saúde sistêmica. Huang *et al.* (2022) destacam que as alterações microvasculares e neurais da retina refletem processos fisiopatológicos presentes em diferentes órgãos, permitindo que algoritmos identifiquem padrões associados não apenas a doenças oftalmológicas, mas também a condições cardiovasculares, metabólicas e neurológicas. Em uma revisão recente, Wang *et al.* (2025) descrevem esse conceito sob a perspectiva da "oculômica", campo que integra big data e IA para extrair, a partir de fotografias de fundo de olho e exames de OCT/OCTA, informações quantitativas sobre a microvasculatura e a arquitetura neural da retina com potencial valor preditivo para doenças sistêmicas, especialmente doenças cardiovasculares e doença renal crônica.

Um dos exemplos mais notáveis dessa abordagem é o modelo fundacional RETFound, desenvolvido por Zhou *et al.* (2023), que demonstrou capacidade de generalização para tarefas de diagnóstico e predição utilizando imagens

retinianas. Além de aplicações em doenças oftalmológicas, o modelo foi capaz de prever desfechos sistêmicos complexos, incluindo insuficiência cardíaca e infarto agudo do miocárdio, a partir do mesmo tipo de imagem utilizado no diagnóstico da retinopatia diabética, da degeneração macular relacionada à idade e de outras doenças da retina. Esses resultados reforçam o conceito da retina como uma janela não invasiva para a saúde sistêmica.

Limitações

Apesar de a IA apresentar inúmeros benefícios e perspectivas futuras, a implementação nos sistemas de saúde é complexa, envolvendo desafios desde a aquisição de dados e o desenvolvimento tecnológico até a aplicação clínica e questões éticas e sociais (AUNG *et al.*, 2021), conforme será discutido nos próximos parágrafos.

Base de dados

O desenvolvimento de modelos de IA depende da disponibilidade de bases de dados robustas, representativas e de alta qualidade. No entanto, a fragmentação dos sistemas de saúde, a heterogeneidade dos sistemas de informação e a baixa interoperabilidade entre instituições dificultam o compartilhamento e a integração desses dados. Como consequência, o treinamento e a validação dos algoritmos podem ser realizados com amostras insuficientes ou pouco representativas, comprometendo sua capacidade de generalização para diferentes populações e contextos clínicos. A sub-representação de determinados grupos também pode intensificar vieses preexistentes e ampliar desigualdades diagnósticas, de acordo com as características da população utilizada no desenvolvimento de cada modelo (AUNG *et al.*, 2021).

Dados desbalanceados, por uma limitação de representatividade e espectro, exigem critérios de coletas cuidadosas. Critérios de seleção excessivamente abrangentes podem aumentar a ocorrência de falsos positivos, gerando incerteza para o paciente e expondo-o potencialmente à realização de exames complementares desnecessários. Em contrapartida, critérios excessivamente restritivos podem favorecer falsos negativos e impedir a identificação de indivíduos que se beneficiariam de acompanhamento especializado (SAVASTANO *et al.*, 2025). Adicionalmente, a natureza dinâmica dos dados em saúde - frequentemente incompletos, inconsistentes, despadronizados e sujeitos à rápida obsolescência - pode comprometer o desempenho preditivo dos modelos e limitar sua generalização para diferentes cenários clínicos.

Desenvolvimento tecnológico

O desenvolvimento de algoritmos de IA na saúde enfrenta desafios metodológicos, especialmente relacionados aos vieses, que podem gerar erros sistemáticos e decisões indevidas. Esses vieses surgem devido a dados de treinamento pouco representativos, falhas no desenvolvimento dos algoritmos ou diferenças entre o ambiente de treinamento e a prática clínica. González-Gonzalo *et al.* (2022) descreveram dois principais vieses que encontramos no desenvolvimento de modelos de IA na saúde: o viés de fonte, que reduz a capacidade de generalização para diferentes populações, e o viés de contexto, no qual o algoritmo aprende associações inadequadas em vez de identificar os verdadeiros marcadores da doença.

Outra limitação é de natureza cultural, especialmente no que se refere à interação de profissionais de saúde e pacientes com esse tipo de tecnologia. Por um lado, a confiança excessiva

dos profissionais nas recomendações produzidas por sistemas de IA, fenômeno conhecido como viés de automação, pode comprometer a avaliação crítica e favorecer a aceitação de resultados inadequados sem a devida correlação clínica. Por outro, a desconfiança em relação à IA, a baixa compreensão de seu funcionamento e a percepção de perda de autonomia podem gerar resistência entre profissionais e pacientes, limitando sua aceitação e incorporação à prática assistencial (SAVASTANO *et al.*, 2025).

Além disso, a chamada mudança de domínio (*domain shift*) é um desafio relevante, que ocorre quando as características dos dados encontrados na prática clínica diferem daquelas utilizadas no treinamento e na validação dos modelos de IA. Essas diferenças podem decorrer de alterações na população estudada, nos critérios diagnósticos e terapêuticos, nos equipamentos, nos protocolos de aquisição de dados e na própria evolução das doenças. Como consequência, o desempenho do algoritmo pode diminuir quando aplicado a cenários distintos daqueles para os quais foi originalmente desenvolvido e validado, reforçando a necessidade de monitoramento contínuo e reavaliação periódica dos modelos (SAVASTANO *et al.*, 2025).

Implementação clínica

No contexto da implementação clínica, observa-se uma lacuna significativa entre o desempenho demonstrado em ambientes experimentais e sua efetividade na prática assistencial, pois muitos deles foram derivados de estudos retrospectivos e há escassez de evidências prospectivas e multicêntricas que comprovem benefícios clínicos consistentes. Sua adoção depende da integração com os sistemas de saúde, da facilidade de uso das plataformas, da capacitação dos profissionais e do envolvimento das partes interessadas no desenvolvimento da tec-

nologia. A adequação da IA ao fluxo de trabalho clínico é essencial para evitar dificuldades de utilização e garantir sua implementação eficaz (AUNG *et al.*, 2021).

Privacidade do paciente e questões éticas

As preocupações relacionadas à privacidade, a segurança da informação e as questões éticas constituem outro importante obstáculo para a expansão da IA na saúde. (SAVASTANO *et al.*, 2025) defendem que o uso dessas tecnologias deve respeitar os princípios da bioética (beneficência, não maleficência, justiça e autonomia), garantindo benefícios aos pacientes, minimizando riscos, promovendo equidade e assegurando consentimento informado, transparência e confidencialidade dos dados. Assim como em qualquer procedimento clínico, os pacientes devem receber informações claras e compreensíveis sobre a finalidade, os benefícios, os riscos e as limitações da utilização de sistemas de IA, bem como sobre o tratamento de seus dados pessoais.

Os modelos de IA exigem grandes volumes de dados clínicos de qualidade, o que aumenta preocupações com a proteção da privacidade. A oftalmologia, em especial, enfrenta desafios adicionais, uma vez que determinadas características anatômicas, como a vascularização da retina em uma imagem de fundo de olho, podem funcionar como identificadores biométricos, dificultando a completa anonimização dos pacientes e aumentando o risco de reidentificação, mesmo após processos de anonimização. Até mesmo o “direito do esquecimento”, que permite aos pacientes a exclusão de seus dados, pode ser ameaçado com a retenção prolongada de informações, falha de exclusão e ataques cibernéticos (SAVASTANO *et al.*, 2025). Além disso, a pesquisa de Tom *et al.*, (2020) expõe que a crescente colaboração entre instituições

de saúde, empresas farmacêuticas e organizações de tecnologia amplia as preocupações quanto ao uso comercial de informações clínicas e à necessidade de garantir que o compartilhamento de dados ocorra de forma ética, transparente e voltada ao interesse coletivo.

Embora as legislações de proteção de dados fortaleçam a privacidade, elas também podem dificultar o compartilhamento de informações para pesquisa e desenvolvimento de modelos mais robustos. Por fim, a inexistência de marcos regulatórios internacionalmente harmonizados e de diretrizes sobre o uso ético da IA na saúde, contribui para aumento de incertezas, negligências e subaproveitamento dos sistemas, reforçando a necessidade de supervisão humana e transparência sobre as capacidades e restrições da IA (AUNG *et al.*, 2021).

Segurança do paciente e questões sociais

Questões relacionadas à responsabilização por erros diagnósticos ou terapêuticos têm trazido debates sobre a confiabilidade e adesão da IA nos sistemas de saúde. Nesse contexto, surgiu o conceito “*black box*” (caixa preta). A problemática acerca da caixa preta reside em 3 princípios: transparência, interpretabilidade e explicabilidade. A falta de transparência é traduzida na dificuldade de compreensão pelo indivíduo do funcionamento do modelo de IA e de como os dados estão sendo usados. A falha na interpretabilidade influencia os resultados do modelo e sua explicação. A explicabilidade, por sua vez, se torna problemática na incapacidade de geração de justificativas compreensíveis para as decisões ou previsões realizadas pelo sistema (SAVASTANO *et al.*, 2025). A fragilidade do fenômeno da caixa preta mostra-se crítica quando um modelo de IA não apresenta o desempenho esperado ou fornece respostas incorretas, suscitando a discussão sobre a respon-

sabilização sobre erro no diagnóstico ou recomendação de tratamento de uma doença. Assim, a limitada transparência dos sistemas de IA pode comprometer a relação entre profissionais de saúde e reduzir a confiança dos pacientes tanto na validação das decisões clínicas quanto na utilização da IA como ferramenta de apoio à assistência (COSTIN *et al.*, 2025).

O conceito de lacuna de responsabilidade (AUNG *et al.*, 2021) se caracteriza pela dificuldade de definir claramente quem deve responder por eventuais danos causados por sistemas inteligentes complexos. A relação entre a confiança do médico nos sistemas de IA e a responsabilização legal torna-se complexa quando os profissionais utilizam recomendações algorítmicas sem compreender plenamente os mecanismos que fundamentam as decisões produzidas pelo sistema. Espera-se que o profissional valide criticamente as recomendações fornecidas pelo sistema e assegure que as decisões estejam alinhadas ao padrão de cuidado estabelecido pela prática médica vigente. Entretanto, esse modelo jurídico pode reduzir a adoção de sistemas de IA potencialmente superiores ao desempenho humano em determinadas tarefas, devido ao receio dos profissionais em delegar parte da tomada de decisão aos algoritmos.

As denominadas “alucinações” (WONG *et al.*, 2024) representam o potencial da IA robótica para produzir resultados imprecisos ou enganosos e gerar informações incorretas, favorecendo diagnósticos equivocados e tratamentos inadequados, especialmente quando há confiança excessiva nas recomendações da IA. Os algoritmos também podem apresentar desempenho reduzido diante de casos clínicos complexos, dados diferentes dos utilizados no treinamento e dados defasados, quando não são atualizados conforme a evolução do conhecimento médico.

Estratégias para mitigar as limitações da IA

Para contornar desafios relacionados à disponibilidade de bases de dados amplas, padronizadas e representativas estratégias como aumento de dados, geração de imagens sintéticas por redes adversariais generativas (GANs), grandes modelos de linguagem (LLMs) e o uso de grandes registros eletrônicos de saúde têm apresentado importantes avanços, ampliando a capacidade de treinamento e o desempenho dos modelos (VAMSIDHAR *et al.*, 2026). A redução de vieses exige cuidados em todas as etapas do desenvolvimento dos algoritmos, incluindo a construção de bases de dados diversas, definição adequada das tarefas, padronização do pré-processamento, prevenção de vazamento de dados, validação em conjuntos externos representativos, adaptação dos limiares de decisão ao contexto assistencial e monitoramento contínuo após a implantação clínica (NAKAYAMA *et al.*, 2024). Essas medidas aumentam a capacidade de generalização e de atualização, a confiabilidade e a segurança dos sistemas.

A proteção da privacidade é favorecida por tecnologias como - aprendizado federado, criptografia avançada, anonimização, pseudonimização, privacidade diferencial, computação segura multipartidária, provas de conhecimento zero, *machine unlearning* e *swarm learning*, que permitem o desenvolvimento colaborativo de modelos preservando a confidencialidade das informações dos pacientes e atendendo às exigências regulatórias. A aprendizagem federada tem se destacado por possibilitar o treinamento descentralizado de modelos utilizando dados distribuídos entre diferentes instituições, ou seja, compartilhando apenas os parâmetros dos modelos, e não os dados dos pacientes (SAVASTANO *et al.*, 2025).

Por fim, incorporação de métodos como a IA explicável (XAI) tem contribuído para aumentar a transparência das decisões dos modelos, favorecendo a interpretabilidade e a confiança dos profissionais de saúde. A IA, ao integrar diferentes modalidades de dados em sua capacidade multimodal, evolui de aplicações diagnósticas para sistemas capazes de prever a progressão das doenças, estimar respostas terapêuticas e apoiar a medicina personalizada (SAVASTANO *et al.*, 2025). Na prática clínica, essa abordagem tem demonstrado grande potencial no diagnóstico e planejamento terapêutico de doenças oftalmológicas. Em doenças da retina, modelos como *EyeCLIP* e *EyeFound* aprimoram a identificação de alterações vasculares e estruturais, enquanto, no glaucoma, a integração de fundoscopia, OCT, espessura da camada de fibras nervosas da retina e perimetria aumenta a precisão diagnóstica e a avaliação da gravidade da doença.

Savastano *et al.* (2025) apontam que apesar do receio de substituição de profissionais, as evidências indicam que a IA atua principalmente como ferramenta de apoio, aumentando a eficiência, a precisão diagnóstica e o acesso aos cuidados, especialmente em regiões com escassez de especialistas ou alta prevalência de doenças. Posto isso, o julgamento clínico, a comunicação, a consideração de preferências pessoais e a tomada de decisões personalizadas permanecem dependentes do profissional de saúde. Em contrapartida, o estudo afirma que existem expectativas excessivamente otimistas acerca das capacidades atuais da IA, o que também pode gerar frustração e perda de confiança quando os resultados observados não correspondem às expectativas ou não são utilizados da forma correta, exigindo treinamento das equipes de saúde para seu uso.

Conclusão

As retinopatias constituem um importante problema de saúde pública e permanecem entre as principais causas de deficiência visual e cegueira evitável no mundo. Nesse contexto, o rastreamento sistemático e o diagnóstico precoce são estratégias essenciais para reduzir a perda visual e preservar a qualidade de vida dos pacientes. A IA consolidou-se como uma das aplicações mais promissoras da medicina baseada em imagens, encontrando na oftalmologia um cenário particularmente favorável devido à ampla disponibilidade de exames digitais padronizados.

As evidências apresentadas demonstram que a IA alcançou elevado desempenho no rastreamento da RD e apresenta resultados promissores para a DMRI, ROP, oclusão venosa da retina e o descolamento de retina. Além da detecção automatizada de doenças, essas tecnologias ampliam as possibilidades de estratificação de risco, prognóstico e integração multimodal de dados, contribuindo para uma assistência mais precisa e eficiente.

Embora ainda existam desafios relacionados à implementação clínica, à qualidade dos dados, à validação dos modelos e aos aspectos éticos e regulatórios, os avanços recentes indicam uma evolução contínua dessas tecnologias. Assim, a IA não deve ser compreendida como substituta do oftalmologista, mas como uma ferramenta complementar capaz de ampliar a eficiência dos programas de rastreamento, otimizar a utilização dos recursos em saúde e expandir o acesso ao diagnóstico especializado. À medida que novas evidências consolidarem sua segurança e efetividade em cenários reais, a IA tende a desempenhar um papel cada vez mais relevante na prevenção da cegueira evitável e na construção de uma oftalmologia mais precisa, acessível e personalizada.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABRÀMOFF MD, *et al.* Pivotal trial of an autonomous AI-based diagnostic system for detection of diabetic retinopathy in primary care offices. *npj Digital Medicine*, v. 1, p. 39, 2018. DOI: 10.1038/s41746-018-0040-6.
- AKIL, M. *et al.* Detection of retinal abnormalities in fundus image using CNN deep learning networks. In: *State of the art in neural networks and their applications*. [S.l.]: Elsevier; p. 19-61, 2021.
- ALZUBAIDI, L. *et al.* Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, v. 8, n. 1, p. 53, 2021. DOI: 10.1186/s40537-021-00444-8.
- AUNG, Y.Y.M. *et al.* The promise of artificial intelligence: a review of the opportunities and challenges of artificial intelligence in healthcare. *British Medical Bulletin*, v. 139, n. 1, p. 4-15, 2021. DOI: 10.1093/bmb/ldab016.
- BERRADA L, *et al.* Real-world performance of an AI system for diabetic retinopathy screening. *Scientific Reports*. v. 16, p. 7609, 2026. DOI: 10.1038/s41598-026-37292-6.
- COSTIN, H.N. *et al.* Artificial intelligence in ophthalmology: advantages and limits. *Applied Sciences*. v. 15, n. 4, p. 1913, 2025. DOI: 10.3390/app15041913
- DI GIAMMARCO, M. *et al.* Explainable retinal disease classification and localization through convolutional neural networks. *Image and Vision Computing*, v. 162, p. 105667, 2025. DOI: 10.1016/j.imavis.2025.105667.
- GONZÁLEZ-GONZALO, C. *et al.* Trustworthy AI: closing the gap between development and integration of AI systems in ophthalmic practice. *Progress in Retinal and Eye Research*. v. 90, p. 101034, 2022. DOI: 10.1016/j.preteyeres.2021.101034.
- GULSHAN, V. *et al.* Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA*; v. 316, n. 22, p. 2402-2410, 2016. DOI: 10.1001/jama.2016.17216.
- HAILU, A.A. *et al.* Early retinal disease detection from fundus images using deep neural networks. *Scientific Reports*. 2026. 16, Article number: 17773. DOI: 10.1038/s41598-026-42059-0.
- HUANG, X. *et al.* Artificial intelligence promotes the diagnosis and screening of diabetic retinopathy. *Frontiers in Endocrinology*, v. 13, p. 946915, 2022. DOI: 10.3389/fendo.2022.946915.
- LIM, J.I. *et al.* Artificial intelligence for retinal diseases. *Asia-Pacific Journal of Ophthalmology*, v. 13, n. 4, p. 100096, 2024. DOI: 10.1016/j.apjo.2024.100096.
- MAITRA, P. *et al.* The scope of artificial intelligence in retinopathy of prematurity (ROP) management. *Indian Journal of Ophthalmology*, v. 72, n. 7, p. 931-934, 2024. DOI: 10.4103/IJO.IJO_2544_23.
- NAKAYAMA, L.F. *et al.* Unmasking biases and navigating pitfalls in the ophthalmic artificial intelligence lifecycle: a narrative review. *PLOS Digital Health*, v. 3, n. 10, p. e0000618, 2024. doi: 10.1371/journal.pdig.0000618.
- NAGASATO, D. *et al.* Automated detection of a nonperfusion area caused by retinal vein occlusion in optical coherence tomography angiography images using deep learning. *PLoS One*, v. 14, n. 11, p. e0223965, 2019. DOI: 10.1371/journal.pone.0223965.
- OHSUGI, H. *et al.* Accuracy of deep learning, a machine-learning technology, using ultra-wide-field fundus ophthalmoscopy for detecting rhegmatogenous retinal detachment. *Scientific Reports*, v. 7, p. 9425, 2017. DOI: 10.1038/s41598-017-09891-x.
- PARMAR, U.P.S. *et al.* Artificial intelligence for early diagnosis of retinal diseases. *Medicina*, v. 60, n. 4, p. 527, 2024. DOI: 10.3390/medicina60040527.

PENG, Y. *et al.* DeepSeeNet: a deep learning model for automated classification of patient-based age-related macular degeneration severity from color fundus photographs. *Ophthalmology*, v. 126, n. 4, p. 565-575, 2019. DOI: 10.1016/j.ophtha.2018.11.015.

SABRI, K. *et al.* Retinopathy of prematurity: a global perspective and recent developments. *Pediatrics*, v. 150, n. 3, p. e2021053924, 2022. DOI: 10.1542/peds.2021-053924.

SAVASTANO, M.C. *et al.* Artificial intelligence in ophthalmology: progress, challenges, and ethical implications. *Progress in Retinal and Eye Research*, v. 107, p. 101374, 2025. DOI: 10.1016/j.preteyeres.2025.101374.

TING, D.S.W. *et al.* Development and validation of a deep learning system for diabetic retinopathy and related eye diseases using retinal images from multiethnic populations with diabetes. *JAMA*, v. 318, n. 22, p. 2211-2223, 2017. DOI: 10.1001/jama.2017.18152.

TOM, E. *et al.* Protecting data privacy in the age of AI-enabled ophthalmology. *Translational Vision Science & Technology*, v. 9, n. 2, p. 36, 2020. DOI: 10.1167/tvst.9.2.36.

VAMSIDHAR, D. *et al.* Advancements in ophthalmology healthcare using multimodal AI: a systematic review of methods, applications, and future directions. *Discover Artificial Intelligence*, v. 6, p. 236, 2026. DOI: 10.1007/s44163-026-00980-3.

VUJOSEVIC, S. *et al.* Screening for diabetic retinopathy: new perspectives and challenges. *The Lancet Diabetes & Endocrinology*, v. 8, n. 4, p. 337-347, 2020. DOI: 10.1016/S2213-8587(19)30411-5.

WALDSTEIN, S.M. *et al.* Evaluating the impact of vitreomacular adhesion on anti-VEGF therapy for retinal vein occlusion using machine learning. *Scientific Reports*, v. 7, article number: 2928, 2017. DOI: 10.1038/s41598-017-02971-y

WANG, J. *et al.* Artificial intelligence-enhanced retinal imaging as a biomarker for systemic diseases. *Theranostics*, v. 15, n. 8, p. 3223-3233, 2025. DOI: 10.7150/thno.100786.

WONG, I.N. *et al.* Leveraging foundation and large language models in medical artificial intelligence. *Chinese Medical Journal*, v. 137, n. 21, p. 2529-2539, 2024. DOI: 10.1097/CM9.00000000000003302.

WINEBRAKE, J.P. & LIM, J.I. Retinal imaging and artificial intelligence analysis. In: *Handbook of Clinical Neurology*. [S.l.]: Elsevier; v. 218, p.3-12. 2026. DOI: 10.1016/B978-0-443-22212-2.00011-2.

WORLD HEALTH ORGANIZATION. Vision impairment and blindness. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/blindness-and-visual-impairment>. Acesso em: 15 jun. 2026.

ZHOU, Y. *et al.* A foundation model for generalizable disease detection from retinal images. *Nature*, v. 622, n. 7981, p. 156-163, 2023. DOI: 10.1038/s41586-023-06555-x.