

Oftalmologia e Otorrinolaringologia

Edição IX

Capítulo 25

INTELIGÊNCIA ARTIFICIAL NA OFTALMOLOGIA: APLICAÇÕES ATUAIS E PERSPECTIVAS FUTURAS

JULIA BASOLLI GOMIERO¹

¹Centro Universitário FMABC.

Palavras-chave: Inteligência artificial; Oftalmologia; Aprendizado de máquina.

DOI

10.59290/9100272204

EP EDITORA
PASTEUR

INTRODUÇÃO

Transformação digital na medicina

Nas últimas décadas, a transformação digital promoveu mudanças profundas na prática médica, impulsionadas pela informatização dos serviços de saúde, pela expansão dos prontuários eletrônicos e pela incorporação de métodos diagnósticos digitais. Como consequência, houve um crescimento expressivo da quantidade de informações clínicas disponíveis, incluindo exames laboratoriais, dados de imagem e registros eletrônicos de saúde, tornando cada vez mais complexa sua interpretação pelo profissional de saúde. Nesse cenário, surgiu a necessidade de ferramentas capazes de organizar, integrar e analisar grandes volumes de dados de forma rápida e consistente, favorecendo a tomada de decisão clínica (AHUJA *et al.*, 2022; AUNG; WONG; TING, 2021).

A inteligência artificial (IA) consolidou-se como uma das principais tecnologias desenvolvidas para atender essa demanda. Sua incorporação à assistência médica vem permitindo automatizar tarefas repetitivas, otimizar fluxos de trabalho e oferecer suporte ao diagnóstico, ao prognóstico e ao monitoramento de pacientes, contribuindo para uma prática clínica mais eficiente e baseada em dados (BEKBOLATOVA *et al.*, 2024; BOHR; MEMARZADEH, 2020).

Este capítulo tem como objetivo apresentar os fundamentos da IA aplicados à oftalmologia, discutir as aplicações da IA nas doenças oftalmológicas mais prevalentes, analisar seus benefícios e limitações e explorar as perspectivas futuras para sua incorporação à prática clínica.

Inteligência artificial na saúde

A rápida evolução da capacidade computacional, aliada ao desenvolvimento de algoritmos cada vez mais sofisticados e à disponibilidade de grandes bases de dados, ampliou significativamente as possibilidades de aplicação da

IA na saúde. Atualmente, essas tecnologias estão presentes em diferentes etapas da assistência, incluindo apoio ao diagnóstico, estratificação de risco, predição prognóstica, monitoramento clínico e automatização de processos administrativos (AUNG; WONG; TING, 2021; BOHR; MEMARZADEH, 2020; BEKBOLATOVA *et al.*, 2024).

Além da prática assistencial, a IA também vem transformando a pesquisa biomédica, contribuindo para a descoberta de novos fármacos, identificação de biomarcadores, medicina de precisão e planejamento de ensaios clínicos. Apesar do elevado potencial, essas ferramentas não têm como objetivo substituir o profissional de saúde, mas ampliar sua capacidade de interpretação e apoiar a tomada de decisões fundamentadas em grandes volumes de informação (ALZUBAIDI *et al.*, 2021; BAJWA *et al.*, 2021; BEKBOLATOVA *et al.*, 2024; BOHR; MEMARZADEH, 2020).

A oftalmologia como especialidade ideal para a inteligência artificial

A oftalmologia destaca-se entre as especialidades médicas como uma das áreas mais favoráveis à aplicação da IA. Essa característica decorre principalmente da ampla utilização de exames de imagem digitais padronizados, que geram dados de alta qualidade e permitem o treinamento de algoritmos com elevado desempenho diagnóstico. Como consequência, algoritmos de IA vêm demonstrando desempenho promissor no rastreamento, diagnóstico, classificação e monitoramento de doenças oculares (AHUJA *et al.*, 2022; BAJWA *et al.*, 2021; BEKBOLATOVA *et al.*, 2024; CHOI *et al.*, 2020; COSTIN; FIRA; GORAŞ, 2025; OLAWADE *et al.*, 2025; RIZWAN KHAN; MALIK, 2025).

Outro fator que impulsiona o uso da IA na oftalmologia é sua integração com a telemedicina. A possibilidade de aquisição remota de

imagens e sua análise automatizada pode ampliar o acesso ao diagnóstico especializado, fortalecer programas de rastreamento populacional e otimizar o encaminhamento de pacientes, especialmente em regiões com limitada disponibilidade de oftalmologistas (COSTIN; FIRA; GORAŞ, 2025; JIN; YE, 2022; OLAWADE *et al.*, 2025).

MÉTODO

Trata-se de uma revisão narrativa da literatura, realizada entre os meses de junho e julho de 2026, com o objetivo de reunir e sintetizar as principais evidências científicas sobre as aplicações atuais e as perspectivas futuras da inteligência artificial (IA) na oftalmologia. A busca bibliográfica foi conduzida nas bases de dados PubMed/MEDLINE e Google Scholar, com buscas atualizadas até julho de 2026, utilizando combinações dos descritores em inglês *Artificial Intelligence*, *Machine learning*, *Deep learning*, *Ophthalmology*, *Diabetic Retinopathy*, *Age-Related Macular Degeneration*, *Glaucoma*, *Retinal Diseases*, *Optical Coherence Tomography* e *Fundus Photography*. As estratégias de busca foram adaptadas às características de cada base de dados. Também foram consultados diretrizes, consensos e artigos relevantes para contextualização dos conceitos fundamentais da IA e de sua aplicação na medicina e na oftalmologia.

Foram incluídos artigos publicados entre 2016 e 2026, no idioma inglês e disponíveis na íntegra, abrangendo revisões narrativas, revisões sistemáticas, meta-análises, estudos observacionais e pesquisas originais que abordassem o desenvolvimento, a validação ou a aplicação clínica de algoritmos de IA em oftalmologia. Também foram incluídos diretrizes, consensos e documentos relevantes para contextualização do tema.

Foram excluídas publicações que não abordavam diretamente a aplicação da inteligência

artificial na medicina ou na oftalmologia, bem como estudos cuja temática não contribuía para os objetivos desta revisão. Também foram considerados resumos de congressos, cartas ao editor, artigos duplicados e estudos sem acesso ao texto completo.

Os estudos selecionados foram analisados de forma crítica e descritiva, buscando sintetizar as principais evidências disponíveis sobre os conceitos fundamentais da inteligência artificial e suas aplicações nas principais doenças oftalmológicas. Além disso, foram abordados aspectos relacionados à implementação clínica, às limitações atuais, às questões éticas e regulatórias, às perspectivas futuras, à inteligência artificial generativa e à integração dessas tecnologias à prática oftalmológica. Por se tratar de uma revisão narrativa, a seleção dos estudos foi baseada em sua relevância científica e pertinência ao tema, não sendo adotado um protocolo sistemático de identificação e elegibilidade nem elaborado fluxograma de seleção dos estudos.

FUNDAMENTOS DA INTELIGÊNCIA ARTIFICIAL

Conceito de inteligência artificial

A IA é um campo da ciência da computação dedicado ao desenvolvimento de sistemas capazes de executar tarefas que normalmente exigem inteligência humana, como reconhecimento de padrões, aprendizado, raciocínio e tomada de decisão. A IA engloba diferentes abordagens computacionais, entre as quais se destacam o *machine learning* (ML) e o *Deep learning* (DL), responsáveis pela maior parte das aplicações atuais na medicina e na oftalmologia. Diferentemente dos sistemas baseados em regras fixas, esses métodos aprendem diretamente a partir dos dados e podem melhorar seu desempenho durante o treinamento, conforme são expostos a novos exemplos (AHMED *et al.*, 2023; BAJWA *et al.*, 2021; COSTIN; FIRA; GORAŞ, 2025; SAVASTANO *et al.*, 2025).

Machine learning

O *machine learning* (ML) é um subcampo da IA no qual os algoritmos aprendem padrões a partir de conjuntos de dados, sem necessidade de programação específica para cada tarefa, embora modelos tradicionais de ML ainda dependam frequentemente da seleção manual de características pelos pesquisadores, conforme detalhado a seguir. Após o treinamento, esses modelos podem realizar classificações, reconhecer padrões e gerar previsões com base no conhecimento adquirido (BAJWA *et al.*, 2021; BEKBOLATOVA *et al.*, 2024; COSTIN; FIRA; GORAŞ, 2025; RIZWAN KHAN; MALIK, 2025; SAVASTANO *et al.*, 2025).

Os algoritmos de ML podem ser classificados em aprendizado supervisionado, não supervisionado e por reforço. Na medicina, o aprendizado supervisionado é o mais empregado, principalmente no desenvolvimento de modelos para classificação de imagens e previsão de desfechos clínicos. O aprendizado não supervisionado é utilizado para identificar agrupamentos e padrões ocultos nos dados, enquanto o aprendizado por reforço baseia-se na interação do algoritmo com o ambiente para otimizar decisões por meio de recompensas e penalizações (ALZUBAIDI *et al.*, 2021; BAJWA *et al.*, 2021; CHOI *et al.*, 2020; COSTIN; FIRA; GORAŞ, 2025).

Embora o ML tenha impulsionado importantes avanços na análise de dados médicos, muitos algoritmos tradicionais dependem da seleção e da extração prévia de características relevantes dos dados pelo pesquisador. Com o aumento da complexidade das imagens médicas e da disponibilidade de grandes bases de dados, o *Deep learning* passou a se destacar por aprender automaticamente essas características diretamente dos dados, tornando-se atualmente a principal abordagem para análise automatizada de imagens oftalmológicas.

Deep learning

O *Deep learning* (DL) é um subcampo do ML baseado em redes neurais artificiais compostas por múltiplas camadas de processamento. Diferentemente dos métodos tradicionais de ML, nos quais frequentemente é necessária a extração manual de atributos relevantes, os modelos de DL aprendem automaticamente representações hierárquicas dos dados durante o treinamento, identificando as características mais importantes diretamente das imagens. Essa capacidade tornou o DL especialmente eficaz para tarefas de visão computacional e análise de imagens médicas (ALZUBAIDI *et al.*, 2021; BOHR; MEMARZADEH, 2020; CHOI *et al.*, 2020; COSTIN; FIRA; GORAŞ, 2025; RIZWAN KHAN; MALIK, 2025; SAVASTANO *et al.*, 2025).

O desenvolvimento do DL foi impulsionado pelo aumento da capacidade computacional, pela disponibilidade de grandes bancos de dados e pelo uso de unidades de processamento gráfico (GPUs), permitindo o treinamento de modelos cada vez mais complexos. Atualmente, essa é a principal estratégia empregada para análise automatizada de imagens médicas, incluindo retinografias, tomografias de coerência óptica (OCT) e outras modalidades de imagem oftalmológica (TING *et al.*, 2019).

Redes neurais convolucionais

As redes neurais convolucionais (Convolutional Neural Networks – CNNs) são uma arquitetura de DL especialmente desenvolvida para o processamento de imagens e constituem a base da maioria dos sistemas de IA aplicados à oftalmologia. Diferentemente dos métodos tradicionais de ML, que frequentemente dependem da extração manual de características, as CNNs aprendem automaticamente representações relevantes diretamente dos pixels da imagem, identificando desde padrões simples,

como bordas, contrastes e texturas, até alterações anatômicas e patológicas mais complexas (ALZUBAIDI *et al.*, 2021; CHOI *et al.*, 2020; OLAWADE *et al.*, 2025).

Sua arquitetura é composta por camadas convolucionais, responsáveis pela extração de características, camadas de pooling, que reduzem a dimensionalidade dos dados e aumentam a robustez do modelo, e camadas totalmente conectadas, responsáveis pela classificação ou predição final. Essa capacidade de aprender automaticamente características em diferentes níveis de complexidade revolucionou a análise automatizada de imagens médicas, tornando as CNNs a principal arquitetura empregada em algoritmos de IA para interpretação de imagem (ALZUBAIDI *et al.*, 2021; CHOI *et al.*, 2020; OLAWADE *et al.*, 2025).

Métricas de avaliação do desempenho diagnóstico

A avaliação do desempenho de algoritmos de IA em tarefas diagnósticas costuma se basear em três métricas complementares. A sensibilidade representa a capacidade do algoritmo de identificar corretamente os casos verdadeiramente positivos (ou seja, pacientes com a doença), enquanto a especificidade representa sua capacidade de identificar corretamente os casos verdadeiramente negativos (pacientes sem a doença). Ambas variam de acordo com o limiar de decisão adotado pelo algoritmo, existindo uma relação de compensação entre elas: ajustes que aumentam a sensibilidade tendem a reduzir a especificidade, e vice-versa.

Para sintetizar esse compromisso em uma única medida, utiliza-se com frequência a área sob a curva ROC (AUC, do inglês *area under the curve*), que representa o desempenho do algoritmo em todos os possíveis limiares de decisão simultaneamente. A AUC varia de 0,5, correspondente a um desempenho equivalente ao acaso, a 1,0, que indica discriminação perfeita

entre casos positivos e negativos. Por sintetizar a capacidade discriminativa ao longo de diferentes limiares, a AUC tornou-se um dos indicadores mais utilizados para relatar e comparar o desempenho de algoritmos de IA na literatura oftalmológica (MCCARTHY *et al.*, 2025).

APLICAÇÕES DA INTELIGÊNCIA ARTIFICIAL NAS DOENÇAS OFTALMOLÓGICAS

Doenças da retina

As doenças da retina concentram o maior número de estudos sobre IA em oftalmologia e representam o principal campo de validação clínica dessas tecnologias. Essa predominância está relacionada à elevada prevalência de doenças retinianas potencialmente causadoras de perda visual, à disponibilidade de grandes bancos de retinografias e exames de tomografia de coerência óptica (OCT) e à presença de alterações morfológicas bem definidas, passíveis de identificação por algoritmos de aprendizado profundo. Como resultado, sistemas de IA vêm sendo desenvolvidos para rastreamento, diagnóstico, classificação da gravidade, monitoramento e estimativa prognóstica de diversas doenças da retina (AHUJA *et al.*, 2022; COSTIN; FIRA; GORAŞ, 2025; OLAWADE *et al.*, 2025).

Entre essas condições, a retinopatia diabética representa a aplicação mais consolidada da IA na prática oftalmológica, sendo também a primeira em que um sistema autônomo recebeu aprovação regulatória para uso clínico. Em 2016, um algoritmo de DL treinado em retinografias alcançou sensibilidade de 97,5% e especificidade de 93,4% para detecção de retinopatia diabética referível em um dos pontos operacionais avaliados, com desempenho elevado em dois conjuntos de validação (GULSHAN *et al.*, 2016). Resultados semelhantes foram obtidos por um sistema treinado em 76.370 imagens de retina e avaliado, para retinopatia diabética, em

112.648 imagens de populações multiétnicas com diabetes, que atingiu sensibilidade de 90,5% e especificidade de 91,6% (AUC de 0,936) para retinopatia diabética referível, reforçando a viabilidade do método em bases de imagem de grande escala (TING *et al.*, 2017).

Esses achados abriram caminho para a primeira autorização regulatória de um sistema de IA totalmente autônomo em qualquer especialidade médica: em 2018, a *Food and Drug Administration* (FDA) autorizou a comercialização do IDx-DR (atualmente denominado LumineticsCore), que dispensa a interpretação de um especialista para emitir o resultado no ponto de atendimento primário. No estudo pivotal, conduzido em 900 pacientes em 10 centros nos EUA, o sistema atingiu sensibilidade de 87,2% e especificidade de 90,7% para detecção de retinopatia diabética acima do estágio leve, frente ao padrão de referência de leitores especializados (ABRÀMOFF *et al.*, 2018). Outros sistemas comerciais, como o EyeArt (Eyenuk), receberam autorização da FDA em 2020 seguindo abordagem semelhante (LIM *et al.*, 2024).

Essa aplicação apresenta especial relevância em programas de rastreamento populacional e teleoftalmologia, nos quais a análise automatizada das imagens contribui para ampliar a cobertura assistencial, otimizar o fluxo de encaminhamento e reduzir a sobrecarga dos serviços especializados (BAJWA *et al.*, 2021; COSTIN; FIRA; GORAŞ, 2025; JIN; YE, 2022; OLAWADE *et al.*, 2025; RIZWAN KHAN; MALIK, 2025).

A IA também tem demonstrado resultados promissores na degeneração macular relacionada à idade (DMRI), principalmente por meio da análise de exames de OCT. Nessa condição, os algoritmos podem auxiliar na identificação de alterações estruturais, classificação dos diferentes estágios da doença e avaliação do risco de progressão, além de fornecer suporte ao

acompanhamento terapêutico. Um exemplo consolidado é o DeepSeeNet, desenvolvido pelo National Eye Institute, que classifica automaticamente a gravidade da DMRI segundo a escala simplificada do AREDS a partir de retinografias bilaterais; em validação com participantes do próprio estudo AREDS, o sistema superou especialistas em retina na classificação por paciente (acurácia de 67,1% vs. 59,9%) e alcançou AUC de 0,94 para detecção de drusas grandes, 0,93 para alterações pigmentares e 0,97 para DMRI avançada (PENG *et al.*, 2019). Outras doenças retinianas também vêm sendo investigadas, incluindo retinopatia da prematuridade, oclusões vasculares da retina e doenças hereditárias, embora essas aplicações ainda apresentem menor volume de evidências quando comparadas à retinopatia diabética e à DMRI (COSTIN; FIRA; GORAŞ, 2025; JIN; YE, 2022; OLAWADE *et al.*, 2025; TING *et al.*, 2019).

Glaucoma

O glaucoma é uma das principais causas de cegueira irreversível no mundo, sendo caracterizado por uma neuropatia óptica progressiva associada à perda de células ganglionares da retina e alterações estruturais do nervo óptico, frequentemente acompanhadas por defeitos característicos do campo visual. Como a doença apresenta evolução silenciosa em suas fases iniciais, o diagnóstico precoce é fundamental para reduzir a perda visual. Nesse contexto, a IA, especialmente por meio de algoritmos de DL baseados em CNNs, tem demonstrado elevada capacidade para identificar sinais sugestivos de neuropatia óptica glaucomatosa em fotografias de fundo de olho e exames de OCT, detectando alterações como aumento da escavação do disco óptico e afinamento da camada de fibras nervosas da retina (RNFL). Estudos de validação em grandes bases de retinografias reportam desempenho elevado, com sistemas atingindo AUC de

0,986, sensibilidade de 95,6% e especificidade de 92,0% (LI *et al.*, 2018), e resultados ainda superiores em validações posteriores, com AUC de 0,996, sensibilidade de 96,2% e especificidade de 97,7% (LIU *et al.*, 2019). Entretanto, estudos de validação externa em cenários reais de triagem revelam desempenho mais heterogêneo, sobretudo quando o algoritmo é aplicado a populações étnica ou demograficamente distintas daquelas utilizadas no treinamento: ao comparar um sistema de IA (originalmente desenvolvido e validado em uma população chinesa) com optometristas em uma coorte do UK Biobank, de composição predominantemente europeia, observou-se sensibilidade significativamente menor para o algoritmo (33,3% vs. 65,1%), ainda que com especificidade superior — resultado que ilustra a diferença frequente entre o desempenho em bases de teste controladas e a aplicação em populações heterogêneas de triagem (JAN *et al.*, 2024). Além disso, modelos de IA podem analisar exames de campo visual e integrar múltiplos parâmetros clínicos e de imagem, contribuindo para o rastreamento, o diagnóstico e a estratificação do risco de progressão da doença (AHUJA *et al.*, 2022; COSTIN; FIRA; GORAŞ, 2025; JIN; YE, 2022; OLAWADE *et al.*, 2025; RIZWAN KHAN; MALIK, 2025; TING *et al.*, 2019).

Doenças do segmento anterior

Embora a maior parte das aplicações da IA esteja concentrada nas doenças retinianas e no glaucoma, seu uso no segmento anterior vem crescendo de forma consistente. Algoritmos desenvolvidos a partir de imagens obtidas por lâmpada de fenda, topografia e tomografia corneana têm demonstrado potencial para auxiliar no diagnóstico, classificação e estratificação da gravidade de diferentes doenças. No ceratocône, algoritmos de DL aplicados a mapas coloridos de topografia corneana por disco de Pla-

cido alcançaram acurácia de 96,6% (sensibilidade de 98,8% e especificidade de 94,4%) na diferenciação entre córneas normais e ectásicas, com capacidade adicional de classificar o estágio da doença segundo a escala de Amsler-Krumeich (KAMIYA *et al.*, 2021).

Além do diagnóstico, modelos de IA vêm sendo explorados para apoiar o planejamento terapêutico e cirúrgico, especialmente na cirurgia de catarata, por meio da classificação da opacidade do cristalino, seleção de pacientes e estimativa de desfechos clínicos. Um exemplo consolidado é o uso de fórmulas de cálculo de lente intraocular (LIO) baseadas em IA, como Hill-RBF e Kane; em estudo retrospectivo com 80 olhos de pacientes com miopia axial extrema (comprimento axial ≥ 30 mm), essas fórmulas atingiram erro absoluto médio de 0,51–0,52 D, valores significativamente inferiores aos da fórmula tradicional SRK/T, reduzindo de 42,5% para 7,5% a proporção de olhos com erro refracional superior a $\pm 1,0$ D; a fórmula Barrett Universal II apresentou desempenho intermediário (0,66 D), sem diferença estatística significativa em relação ao SRK/T (SUZUKI *et al.*, 2025). Apesar dos resultados promissores, essas aplicações ainda apresentam menor nível de maturidade quando comparadas às doenças da retina, refletindo a necessidade de estudos adicionais para validação e incorporação rotineira na prática clínica (AHUJA *et al.*, 2022; BEKBOLATOVA *et al.*, 2024; BOHR; MEMARZADEH, 2020; COSTIN; FIRA; GORAŞ, 2025; JIN; YE, 2022; OLAWADE *et al.*, 2025; RIZWAN KHAN; MALIK, 2025).

Outras aplicações da inteligência artificial na oftalmologia

Na educação médica, a IA tem sido incorporada a plataformas de aprendizagem adaptativa, simuladores cirúrgicos e ambientes de realidade virtual e aumentada, permitindo o trei-

namento seguro de procedimentos e o desenvolvimento progressivo de habilidades clínicas e cirúrgicas. Além de personalizar o processo de aprendizagem de acordo com o desempenho do estudante, essas tecnologias possibilitam avaliações objetivas do treinamento, fornecendo feedback em tempo real e favorecendo a aquisição de competências antes do contato direto com pacientes (BEKBOLATOVA *et al.*, 2024; BOHR; MEMARZADEH, 2020).

Outra aplicação de destaque é a teleoftalmologia, na qual sistemas de IA auxiliam a triagem de pacientes, a interpretação inicial de exames e a definição de prioridades para encaminhamento. Essa estratégia tem potencial para ampliar o acesso à assistência oftalmológica em regiões com escassez de especialistas, reduzindo o tempo entre a identificação da doença e o início do tratamento. Paralelamente, o crescimento dos dispositivos vestíveis (wearables) e das tecnologias de monitoramento remoto permite o acompanhamento contínuo de parâmetros clínicos, favorecendo a detecção precoce de alterações e o seguimento longitudinal de pacientes com doenças crônicas. Além dos benefícios assistenciais, ferramentas baseadas em IA podem aprimorar a comunicação entre médicos e pacientes ao traduzirem informações clínicas complexas em linguagem mais acessível, utilizando recursos visuais e estimativas individualizadas de risco para facilitar a compreensão do diagnóstico, da progressão da doença, das opções terapêuticas e da importância da adesão ao tratamento. Essa abordagem favorece a tomada de decisão compartilhada e pode aumentar o engajamento do paciente no cuidado com a saúde ocular (AUNG; WONG; TING, 2021; BAJWA *et al.*, 2021; BEKBOLATOVA *et al.*, 2024; BOHR; MEMARZADEH, 2020; COSTIN; FIRA; GORAŞ, 2025; JIN; YE, 2022; OLAWADE *et al.*, 2025).

Em diversas subespecialidades da oftalmologia, novas aplicações da IA continuam sendo

desenvolvidas. Na neuro-oftalmologia, CNNs aplicadas a imagens de fundo de olho têm demonstrado capacidade para identificar alterações do disco óptico e diferenciá-las de achados anatômicos normais, contribuindo para o rastreamento de neuropatias ópticas. Na oncologia ocular, modelos de IA vêm sendo investigados para a classificação de tumores, estimativa prognóstica e diferenciação entre lesões benignas e malignas. Na oftalmopatologia, técnicas de patologia digital associadas à IA permitem automatizar a análise histopatológica e aumentar a reprodutibilidade diagnóstica. Na oftalmoplástica, algoritmos de visão computacional auxiliam no planejamento cirúrgico, na análise facial e na avaliação objetiva dos resultados pós-operatórios. Em oftalmologia pediátrica, destacam-se aplicações voltadas ao rastreamento de retinopatia da prematuridade, estrabismo, ambliopia, catarata congênita e outras doenças oculares da infância. Além disso, a IA vem sendo estudada em outras doenças retinianas, incluindo oclusões vasculares da retina, miopia patológica, uveítes e distrofias hereditárias, ampliando continuamente seu campo de atuação (COSTIN; FIRA; GORAŞ, 2025; RIZWAN KHAN; MALIK, 2025; TING *et al.*, 2019).

A automação de processos representa outra importante contribuição da IA para os serviços de oftalmologia. Ferramentas capazes de organizar fluxos de trabalho, priorizar exames conforme o grau de urgência, gerar relatórios preliminares, integrar informações provenientes de diferentes modalidades de imagem e auxiliar na documentação clínica podem reduzir a carga administrativa dos profissionais, aumentar a eficiência operacional e otimizar a utilização dos recursos disponíveis, sem substituir o julgamento clínico do especialista (AHUJA *et al.*, 2022; AUNG; WONG; TING, 2021; BAJWA *et al.*, 2021; BEKBOLATOVA *et al.*, 2024; OLAWADE *et al.*, 2025).

Por fim, a IA também tem demonstrado potencial na reabilitação visual. Dispositivos inteligentes equipados com algoritmos de visão computacional podem reconhecer pessoas, objetos, obstáculos e textos, fornecendo informações em tempo real para indivíduos com baixa visão ou cegueira. Associadas a tecnologias móveis e recursos de acessibilidade, essas soluções favorecem maior autonomia nas atividades diárias, melhor mobilidade e inclusão social, representando uma das áreas mais promissoras para a aplicação da IA centrada no paciente (BOHR; MEMARZADEH, 2020; JIN; YE, 2022).

LIMITAÇÕES E DESAFIOS PARA A IMPLEMENTAÇÃO DA INTELIGÊNCIA ARTIFICIAL NA OFTALMOLOGIA

Apesar dos avanços observados nos últimos anos, a incorporação da IA à prática oftalmológica ainda enfrenta importantes desafios técnicos, clínicos, éticos e regulatórios. Embora diversos algoritmos apresentem elevado desempenho em estudos experimentais, sua utilização rotineira depende da validação em diferentes populações, da integração aos fluxos assistenciais e da aceitação por profissionais de saúde e pacientes. Dessa forma, a implementação segura e eficaz dessas tecnologias requer não apenas o aprimoramento dos modelos computacionais, mas também o desenvolvimento de estratégias que garantam confiabilidade, transparência e aplicabilidade clínica.

Qualidade dos dados e generalização dos modelos

O desempenho de algoritmos de IA depende diretamente da qualidade dos dados utilizados durante seu desenvolvimento. Bases de dados pequenas, pouco representativas ou compostas por imagens obtidas em um único centro podem comprometer a capacidade de generalização dos modelos, reduzindo seu desempenho

quando aplicados em populações distintas ou em equipamentos diferentes daqueles utilizados durante o treinamento. Além disso, inconsistências na rotulagem dos dados, diferenças nos protocolos de aquisição das imagens e variações demográficas entre as populações podem introduzir vieses capazes de afetar a precisão e a confiabilidade dos algoritmos. Outro desafio importante refere-se ao sobreajuste (*overfitting*), situação em que o modelo aprende excessivamente as características do conjunto de treinamento e perde capacidade de adaptação a novos dados. Por esse motivo, a validação externa em bases independentes e multicêntricas é considerada etapa essencial antes da incorporação de sistemas à prática clínica, permitindo avaliar sua robustez e aplicabilidade em diferentes cenários assistenciais (AUNG; WONG; TING, 2021; BEKBOLATOVA *et al.*, 2024; COSTIN; FIRA; GORAŞ, 2025; JIN; YE, 2022; OLAWADE *et al.*, 2025).

Entre as estratégias propostas para mitigar essas limitações, destaca-se o aprendizado federado (*federated learning*), que permite o treinamento colaborativo de algoritmos a partir de dados mantidos localmente em diferentes instituições, sem a necessidade de compartilhamento direto das imagens — abordagem que concilia a necessidade de grandes volumes de dados com as exigências de privacidade e proteção de informações sensíveis (TEO *et al.*, 2025). Essa técnica já foi avaliada para triagem de glaucoma, com desempenho comparável ao de modelos treinados de forma centralizada (BAPTISTA *et al.*, 2023). De forma complementar, técnicas de geração sintética de imagens por redes adversariais generativas (GANs) vêm sendo empregadas para ampliar artificialmente bases de dados de doenças raras ou pouco representadas, contribuindo para reduzir o viés decorrente de bases pequenas e melhorar a capacidade de generalização dos modelos.

Interpretabilidade e confiança clínica

Embora os modelos baseados em DL frequentemente apresentem elevado desempenho diagnóstico, muitos operam como sistemas de "caixa-preta", nos quais o processo utilizado para chegar a determinada decisão não é facilmente compreendido pelo usuário. Essa limitada interpretabilidade representa um dos principais obstáculos para sua adoção clínica, uma vez que médicos e pacientes tendem a confiar mais em sistemas cujos resultados possam ser compreendidos e justificados (AHMED *et al.*, 2023; AHUJA *et al.*, 2022; AUNG; WONG; TING, 2021; COSTIN; FIRA; GORAŞ, 2025; JIN; YE, 2022).

Nesse contexto, cresce o interesse por estratégias de inteligência artificial explicável (*Explainable Artificial Intelligence*), capazes de tornar mais transparente o processo decisório dos algoritmos. Embora essas abordagens possam aumentar a confiança dos profissionais e facilitar a integração da IA à prática clínica, sua aplicação ainda representa um importante campo de pesquisa (COSTIN; FIRA; GORAŞ, 2025).

Aspectos éticos, privacidade e regulamentação

A utilização crescente de IA na saúde também levanta importantes questões éticas relacionadas à privacidade dos pacientes, segurança das informações e responsabilidade sobre as decisões clínicas. O desenvolvimento de algoritmos depende do acesso a grandes volumes de dados, tornando indispensável a adoção de mecanismos capazes de garantir confidencialidade, anonimização e utilização ética dessas informações, em conformidade com a legislação vigente (AHMED *et al.*, 2023; AUNG; WONG; TING, 2021; BEKBOLATOVA *et al.*, 2024; BOHR; MEMARZADEH, 2020; JIN; YE, 2022; OLAWADE *et al.*, 2025; SAVASTANO *et al.*, 2025).

Além disso, falhas na interpretação de exames, classificações incorretas ou recomendações imprecisas podem resultar em atrasos diagnósticos, tratamentos inadequados ou na não identificação de doenças potencialmente graves, colocando a segurança do paciente em risco. Esses aspectos reforçam que as ferramentas de IA devem atuar como sistemas de apoio à decisão clínica, e não como substitutas do julgamento médico, cabendo ao profissional de saúde interpretar criticamente seus resultados e integrá-los ao contexto clínico de cada paciente. Dessa forma, transparência, validação clínica, equidade e monitoramento contínuo dos algoritmos constituem princípios fundamentais para sua utilização responsável. Paralelamente, os avanços da IA têm impulsionado o desenvolvimento de marcos regulatórios destinados a garantir segurança, eficácia e qualidade dessas tecnologias antes de sua implementação clínica (AHMED *et al.*, 2023; AUNG; WONG; TING, 2021; BEKBOLATOVA *et al.*, 2024; BOHR; MEMARZADEH, 2020; JIN; YE, 2022; OLAWADE *et al.*, 2025; SAVASTANO *et al.*, 2025).

Implementação na prática clínica

Aspectos como integração com prontuários eletrônicos, compatibilidade entre diferentes equipamentos, infraestrutura tecnológica, custos de implementação e atualização contínua dos algoritmos influenciam diretamente sua adoção na rotina clínica. Além disso, a incorporação dessas tecnologias exige mudanças nos fluxos de trabalho e adaptação dos serviços de saúde para que a IA seja utilizada de maneira eficiente e segura. Outro desafio relevante refere-se à capacitação dos profissionais de saúde. Embora a IA tenha potencial para apoiar a tomada de decisão clínica, sua utilização adequada depende de que médicos e demais profissionais compreendam seus princípios básicos, potencialidades e limitações. A interpretação

crítica dos resultados gerados pelos algoritmos, o reconhecimento de possíveis erros ou vieses e a integração dessas informações ao contexto clínico permanecem como responsabilidades do profissional. Nesse cenário, iniciativas voltadas à educação e ao treinamento tornam-se cada vez mais importantes para favorecer sua adoção responsável e fortalecer a confiança dos usuários nessas tecnologias (AHMED *et al.*, 2023; AHUJA *et al.*, 2022; AUNG; WONG; TING, 2021; BEKBOLATOVA *et al.*, 2024; JIN; YE, 2022; OLAWADE *et al.*, 2025; SAVASTANO *et al.*, 2025).

PERSPECTIVAS FUTURAS

Os avanços recentes da IA indicam que sua participação na oftalmologia tende a se expandir significativamente nos próximos anos. A evolução dos algoritmos, o aumento da disponibilidade de dados clínicos e de imagem e o desenvolvimento de modelos cada vez mais robustos têm ampliado as possibilidades de aplicação da IA para além do diagnóstico automatizado. Nesse contexto, espera-se que essas tecnologias desempenhem papel crescente no apoio à tomada de decisão clínica, no planejamento terapêutico, na pesquisa científica e na organização dos sistemas de saúde.

Inteligência artificial generativa

Entre os avanços mais recentes destaca-se a inteligência artificial generativa, representada pelos grandes modelos de linguagem (Large Language Models – LLMs), capazes de compreender e gerar textos em linguagem natural. Diferentemente dos modelos tradicionais, desenvolvidos para executar tarefas específicas, esses sistemas apresentam potencial para auxiliar profissionais de saúde em atividades como síntese de informações clínicas, elaboração de documentos, apoio à pesquisa científica e educação médica. Embora sua aplicação direta na oftalmologia ainda esteja em evolução, espera-

se que essas ferramentas contribuam para aumentar a eficiência dos fluxos de trabalho e facilitar o acesso ao conhecimento científico (FENG *et al.*, 2024).

Modelos de fundação e abordagens multimodais

Uma das principais tendências é o desenvolvimento de modelos multimodais, capazes de integrar diferentes fontes de informação para apoiar a tomada de decisão clínica. Um exemplo de modelo de fundação é o RETFound, treinado por aprendizado autossupervisionado em 1,6 milhão de imagens retinianas não rotuladas, capaz de ser adaptado com poucos dados a múltiplas tarefas de diagnóstico e prognóstico; o modelo adaptado superou consistentemente modelos convencionais treinados de forma específica para cada tarefa na detecção e prognóstico de doenças oculares que ameaçam a visão, além de demonstrar capacidade de prever condições sistêmicas complexas — como insuficiência cardíaca e infarto do miocárdio — a partir de imagens de retina, ilustrando o potencial dos modelos de fundação para diferentes aplicações com menor dependência de grandes volumes de dados rotulados (ZHOU *et al.*, 2023).

Enquanto muitos algoritmos atuais são treinados para interpretar uma única modalidade de imagem, como retinografia ou OCT, espera-se que os sistemas futuros combinem simultaneamente exames de imagem, dados clínicos, resultados laboratoriais, informações genéticas e registros eletrônicos de saúde (AHMED *et al.*, 2023; COSTIN; FIRA; GORAŞ, 2025; VAMSIDHAR *et al.*, 2026).

Teleoftalmologia inteligente e medicina personalizada

A análise automatizada de exames obtidos remotamente poderá ampliar o rastreamento populacional, reduzir o tempo entre a aquisição da imagem e a emissão do laudo e otimizar o encaminhamento de pacientes para avaliação

especializada. Essa integração entre IA e telemedicina apresenta potencial para reduzir desigualdades no acesso aos cuidados oftalmológicos, especialmente em regiões com escassez de especialistas ou limitações de infraestrutura (AHUJA *et al.*, 2022; BEKBOLATOVA *et al.*, 2024; BOHR; MEMARZADEH, 2020; COSTIN; FIRA; GORAŞ, 2025; JIN; YE, 2022; OLAWADE *et al.*, 2025).

Paralelamente, espera-se que a IA desempenhe papel cada vez mais relevante na medicina personalizada. A combinação de dados clínicos, exames de imagem e informações provenientes de diferentes modalidades diagnósticas poderá permitir estimativas mais precisas de risco, progressão da doença e resposta ao tratamento, auxiliando na seleção de estratégias terapêuticas individualizadas. Embora muitas dessas aplicações ainda estejam em desenvolvimento, sua incorporação progressiva à prática clínica poderá contribuir para uma assistência mais eficiente, preditiva e centrada nas características de cada paciente (BEKBOLATOVA *et al.*, 2024; JIN; YE, 2022; OLAWADE *et al.*, 2025).

CONSIDERAÇÕES FINAIS

A IA consolidou-se como uma das principais inovações tecnológicas aplicadas à oftalmologia, impulsionando avanços no rastreamento, diagnóstico, monitoramento e planejamento terapêutico de diversas doenças oculares. O desenvolvimento de algoritmos de ML e DL, aliado à crescente disponibilidade de exames de imagem digitais e de bases de dados em larga escala, possibilitou a criação de sistemas capazes de analisar informações complexas

com elevada rapidez e precisão, ampliando as possibilidades de apoio à prática clínica.

Ao longo deste capítulo, foram apresentados os principais conceitos relacionados à IA, suas aplicações nas diferentes áreas da oftalmologia e os desafios envolvidos em sua implementação. Embora os resultados obtidos até o momento sejam promissores, a incorporação dessas tecnologias à rotina assistencial ainda depende da disponibilidade de bases de dados representativas, da validação clínica em diferentes populações, da transparência dos algoritmos, da proteção dos dados dos pacientes e do estabelecimento de marcos regulatórios que garantam sua utilização segura e ética. Além disso, a capacitação dos profissionais de saúde será fundamental para que essas ferramentas sejam utilizadas de forma crítica e integrada ao processo de tomada de decisão clínica.

As perspectivas futuras indicam que a IA deverá assumir um papel cada vez mais abrangente na oftalmologia, impulsionada pelo desenvolvimento de modelos multimodais, pela expansão da teleoftalmologia, pela medicina personalizada e pelos avanços da inteligência artificial generativa. Entretanto, seu maior potencial não reside na substituição do oftalmologista, mas na capacidade de potencializar o julgamento clínico, otimizar fluxos de trabalho e ampliar o acesso a cuidados oftalmológicos de qualidade. Assim, a integração responsável entre inovação tecnológica, evidências científicas e experiência clínica representa o caminho mais promissor para que a IA contribua de forma efetiva para a prevenção da cegueira e para a melhoria da saúde ocular da população.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABRÀMOFF, Michael D. *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, n. 1, p. 39, 2018. DOI: <https://doi.org/10.1038/s41746-018-0040-6>.
- AHMED, Molla Imaduddin *et al.* A Systematic Review of the Barriers to the Implementation of Artificial Intelligence in Healthcare. *Cureus*, v. 15, n. 10, p. e46454, 2023. DOI: <https://doi.org/10.7759/cureus.46454>.
- AHUJA, Abhimanyu S. *et al.* Artificial intelligence in ophthalmology: A multidisciplinary approach. *Integrative Medicine Research*, v. 11, n. 4, p. 100888, 2022. DOI: <https://doi.org/10.1016/j.imr.2022.100888>.
- ALZUBAIDI, Laith *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: <https://doi.org/10.1186/s40537-021-00444-8>.
- AUNG, Yuri Y. M.; WONG, David C. S.; TING, Daniel S. W. 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: <https://doi.org/10.1093/bmb/ldab016>.
- BAJWA, Junaid *et al.* Artificial intelligence in healthcare: transforming the practice of medicine. *Future Healthcare Journal*, v. 8, n. 2, p. e188–e194, 2021. DOI: <https://doi.org/10.7861/fhj.2021-0095>.
- BAPTISTA, Telmo *et al.* Federated Learning for Computer-Aided Diagnosis of Glaucoma Using Retinal Fundus Images. *Applied Sciences (Switzerland)*, v. 13, n. 21, p. 11620, 2023. DOI: <https://doi.org/10.3390/app132111620>.
- BEKBOLATOVA, Molly *et al.* Transformative Potential of AI in Healthcare: Definitions, Applications, and Navigating the Ethical Landscape and Public Perspectives. *Healthcare (Switzerland)*, v. 12, n. 2, p. 125, 2024. DOI: <https://doi.org/10.3390/healthcare12020125>.
- BOHR, Adam; MEMARZADEH, Kaveh. The rise of artificial intelligence in healthcare applications. In: BOHR, Adam; MEMARZADEH, Kaveh (ed.). *Artificial Intelligence in Healthcare*. Academic Press, 2020. p. 25–60. DOI: <https://doi.org/10.1016/B978-0-12-818438-7.00002-2>.
- CHOI, Rene Y. *et al.* Introduction to *Machine learning*, Neural Networks, and *Deep learning*. *Translational Vision Science & Technology*, v. 9, n. 2, p. 14, 27 fev. 2020. DOI: <https://doi.org/10.1167/tvst.9.2.14>.
- COSTIN, Hariton Nicolae; FIRA, Monica; GORAȘ, Liviu. Artificial Intelligence in Ophthalmology: Advantages and Limits. *Applied Sciences (Switzerland)*, v. 15, n. 4, p. 1913, 2025. DOI: <https://doi.org/10.3390/app15041913>.
- FENG, Xiaoru *et al.* Latest developments of generative artificial intelligence and applications in ophthalmology. *Asia-Pacific Journal of Ophthalmology*, v. 13, n. 4, p. 100090, 2024. DOI: <https://doi.org/10.1016/j.apjo.2024.100090>.
- GULSHAN, Varun *et al.* Development and validation of a *Deep learning* algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA - Journal of the American Medical Association*, v. 316, n. 22, p. 2402–2410, 2016. DOI: <https://doi.org/10.1001/jama.2016.17216>.
- JAN, Catherine L. *et al.* Performance of a *Deep learning* System and Performance of Optometrists for the Detection of Glaucomatous Optic Neuropathy Using Colour Retinal Photographs. *Bioengineering*, v. 11, n. 11, p. 1139, 2024. DOI: <https://doi.org/10.3390/bioengineering11111139>.
- JIN, Kai; YE, Juan. Artificial intelligence and *Deep learning* in ophthalmology: Current status and future perspectives. *Advances in Ophthalmology Practice and Research*, v. 2, n. 3, p. 100078, 2022. DOI: <https://doi.org/10.1016/j.aopr.2022.100078>.
- KAMIYA, Kazutaka *et al.* Diagnosability of Keratoconus Using *Deep learning* With Placido Disk-Based Corneal Topography. *Frontiers in Medicine*, v. 8, p. 724902, 2021. DOI: <https://doi.org/10.3389/fmed.2021.724902>.
- LI, Zhixi *et al.* Efficacy of a *Deep learning* System for Detecting Glaucomatous Optic Neuropathy Based on Color Fundus Photographs. *Ophthalmology*, v. 125, n. 8, p. 1199–1206, 2018. DOI: <https://doi.org/10.1016/j.ophtha.2018.01.023>.
- LIM JJ, *et al.* Artificial intelligence for retinal diseases. *Asia Pac J Ophthalmol*. 13(4):100096, 2024. DOI: <https://doi.org/10.1016/j.apjo.2024.100096>.

- LIU, Hanruo *et al.* Development and Validation of a *Deep learning* System to Detect Glaucomatous Optic Neuropathy Using Fundus Photographs. *JAMA Ophthalmology*, v. 137, n. 12, p. 1353–1360, 2019. DOI: <https://doi.org/10.1001/jamaophthalmol.2019.3501>.
- MCCARTHY, Angela *et al.* A Practical Guide to Evaluating Artificial Intelligence Imaging Models in Scientific Literature. *Ophthalmology Science*, v. 5, n. 6, p. 100847, 2025. DOI: <https://doi.org/10.1016/j.xops.2025.100847>.
- OLAWADE, David B. *et al.* Enhancing Ophthalmic Diagnosis and Treatment with Artificial Intelligence. *Medicina (Lithuania)*, v. 61, n. 3, p. 433, 2025. DOI: <https://doi.org/10.3390/medicina61030433>.
- PENG, Yifan *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: <https://doi.org/10.1016/j.ophtha.2018.11.015>.
- RIZWAN KHAN, Arham Yahya; MALIK, Muhammad Bilal. Artificial Intelligence in Ophthalmology: Practical Applications, Subspecialty Evidence and Real-World Deployment. *Cureus*, v. 17, n. 11, p. e96121, 2025. DOI: <https://doi.org/10.7759/cureus.96121>.
- SAVASTANO, Maria Cristina *et al.* Artificial intelligence in ophthalmology: Progress, challenges, and ethical implications. *Progress in Retinal and Eye Research*, v. 107, p. 101374, 2025. DOI: <https://doi.org/10.1016/j.preteyeres.2025.101374>.
- SUZUKI, Yudai *et al.* Artificial intelligence driven intraocular lens power calculation in extreme axial myopia. *Scientific Reports*, v. 15, p. 36921, 2025. DOI: <https://doi.org/10.1038/s41598-025-20899-6>.
- TEO, Zhen Ling *et al.* Privacy-Preserving Technology Using Federated Learning and Blockchain in Protecting against Adversarial Attacks for Retinal Imaging. *Ophthalmology*, v. 132, n. 4, p. 484–494, 2025. DOI: <https://doi.org/10.1016/j.ophtha.2024.10.017>.
- TING, Daniel Shu Wei *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 - Journal of the American Medical Association*, v. 318, n. 22, p. 2211–2223, 2017. DOI: <https://doi.org/10.1001/jama.2017.18152>.
- TING, Daniel Shu Wei *et al.* Artificial intelligence and *Deep learning* in ophthalmology. *British Journal of Ophthalmology*, v. 103, n. 2, p. 167–175, 1 fev. 2019. DOI: <https://doi.org/10.1136/bjophthalmol-2018-313173>.
- 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, n. 1, p. 236, 2026. DOI: <https://doi.org/10.1007/s44163-026-00980-3>.
- ZHOU, Yukun *et al.* A foundation model for generalizable disease detection from retinal images. *Nature*, v. 622, n. 7981, p. 156–163, 2023. DOI: <https://doi.org/10.1038/s41586-023-06555-x>.