

O papel da Inteligência Artificial no rastreio automatizado da retinopatia diabética

Gabriel Bertosin Silva Brito¹, Luiza Ferreira Ventura¹, Izabella do Vale Burjack¹, Cláudia Santos de Oliveira², Salomão Antonio Oliveira³, Eumar Evangelista de Menezes Júnior⁴, Sandro Dutra e Silva⁴

1. Pesquisador vinculado ao Programa de Iniciação Científica e Tecnológica pela Universidade Evangélica de Goiás (UniEVANGÉLICA). Anápolis/GO, Goiás, Brasil.

2. Professora e vice-coordenadora do Programa de Doutorado e Mestrado em Movimento Humano e Reabilitação da UniEVANGÉLICA. Anápolis/GO, Goiás, Brasil.

3. Professor e Preceptor no curso de Medicina da Universidade Evangélica de Goiás (UniEVANGÉLICA). Anápolis/GO, Goiás, Brasil.

4. Professor Permanente do Programa de Doutorado e Mestrado em Sociedade, Tecnologia e Meio Ambiente da Universidade Evangélica de Goiás (UniEVANGÉLICA). Anápolis/GO, Goiás, Brasil. profms.eumarjunior@gmail.com

RESUMO

A retinopatia diabética (RD) é uma complicação microvascular grave da diabetes *mellitus* e uma das principais causas de cegueira evitável em adultos. Este estudo analisa o impacto da Inteligência Artificial (IA) no rastreio automatizado da RD, destacando sua capacidade de melhorar a precisão e a eficiência das triagens. A IA permite a detecção precoce da doença, com a redução da dependência de especialistas e o aumento de acesso a cuidados em regiões com poucos recursos. As tecnologias discutidas incluem algoritmos avançados de aprendizagem profunda e técnicas de explicabilidade, que ajudam a interpretar os resultados clínicos. Apesar dos avanços, barreiras como a falta de padronização de dados, questões éticas e limitações na generalização das estruturas de IA precisam ser superadas. O estudo conclui que a IA representa uma ferramenta promissora no manejo da RD, com potencial para transformar a identificação da doença e prevenir complicações visuais graves em diferentes contextos socioeconômicos.

Palavras-chave: Inteligência Artificial; Retinopatia diabética; Rastreio automatizado.

The role of Artificial Intelligence in the automated screening of diabetic retinopathy

ABSTRACT

Diabetic retinopathy (DR) is a serious microvascular complication of diabetes mellitus and a leading cause of preventable blindness in adults. This study analyzes the impact of Artificial Intelligence (AI) on automated DR screening, highlighting its ability to improve the accuracy and efficiency of screenings. AI enables early detection of the disease, reducing reliance on specialists and increasing access to care in resource-limited regions. The technologies discussed include advanced deep learning algorithms and explainability techniques, which help interpret clinical results. Despite advances, barriers such as a lack of data standardization, ethical issues, and limitations in generalizing AI frameworks need to be overcome. The study concludes that AI represents a promising tool in the management of DR, with the potential to transform disease identification and prevent serious visual complications in different socioeconomic contexts.

Keywords: Artificial intelligence; Diabetic retinopathy; Automated screening.

Introdução

A retinopatia diabética (RD) é uma grave complicaçāo microvascular da diabetes *mellitus* (DM) e uma das maiores causas de cegueira irreversível em todo o mundo, especialmente em indivíduos em idade ativa¹. A Federação Internacional de Diabetes prevê que, até 2040, aproximadamente 600 milhões de pessoas serão diagnosticadas com diabetes e um terço desses indivíduos desenvolverá RD². No Brasil, a situação também apresenta riscos, pois treze milhões de pessoas sofrem de diabetes, mas muitas delas continuam sem conhecimento do diagnóstico³⁻⁴.

A RD afeta de forma progressiva os vasos sanguíneos da retina; portanto, o rastreio regular é essencial para prevenir sua progressão e minimizar o impacto na qualidade de vida dos pacientes⁵⁻⁶. No entanto, apesar de sua importância, o rastreio para RD enfrenta vários desafios, particularmente no âmbito do Sistema Único de Saúde (SUS), onde há limitações no acesso a exames oftalmológicos, como o exame de fundo de olho dilatado e retinografia^{1,7}.

Diversas áreas da medicina foram revolucionadas pela Inteligência Artificial (IA), pois essa tecnologia é capaz de realizar a simulação da inteligência humana por meio de algoritmos e aprendizagem a partir de dados e, com isso, oferece soluções inovadoras para rastreio e tratamento de patologias⁸. Desse modo, destacam-se os avanços significativos na área da oftalmologia, particularmente no rastreio de RD, impulsionados por essa tecnologia que promove a identificação de padrões complexos que seriam de difícil percepção pela análise humana convencional⁸⁻⁹. Os sistemas baseados em IA fazem uso de técnicas de aprendizagem profunda (*deep learning*) e de *Convolutional Neural Networks* (CNN), o que resulta em altos

índices de sensibilidade e especificidade na identificação da RD, superando, em muitos casos, a eficiência de métodos convencionais¹⁰⁻¹¹.

No contexto da IA aplicada à saúde, classificadores são algoritmos que analisam dados de entrada – como imagens de retina – e os atribuem a categorias predefinidas, como “normal” ou “com RD”¹². Esses classificadores são geralmente desenvolvidos com base em paradigmas de aprendizado de máquina supervisionado, nos quais os modelos aprendem a partir de exemplos rotulados, sendo amplamente utilizados na detecção da RD^{11,13}. Por outro lado, os métodos não supervisionados, embora menos comuns nesse campo, são aplicados para identificar padrões ou agrupar dados sem a necessidade de rótulos prévios⁸.

Entre as arquiteturas mais relevantes destacam-se as redes neurais convolucionais (CNNs), amplamente utilizadas na classificação de imagens fundoscópicas¹⁰, e os transformadores visuais, que têm se mostrado promissores por sua capacidade de capturar relações espaciais complexas entre regiões da imagem⁹. Outro conceito fundamental é o de dependência entre dados, especialmente ao lidar com múltiplas imagens de um mesmo paciente, o que pode comprometer a generalização do modelo e introduzir viés se não tratado adequadamente¹⁴⁻¹⁵. A compreensão desses fundamentos é essencial para o desenvolvimento e avaliação de sistemas robustos de rastreio automatizado da RD.

O desenvolvimento de ferramentas baseadas em IA, como o IDx-DR e EyeArt, tem tornado possível o rastreio automatizado da RD, o que reduz a dependência de especialistas e amplia o acesso ao rastreio em regiões de poucos recursos^{11,16}. Além disso, a aplicação de *deep learning* na análise de imagens de retina permitiu avanços na detecção de estágios iniciais da RD, o que reduz a carga de trabalho dos oftalmologistas e melhora a adesão dos pacientes aos programas de rastreio¹⁷.

Todavia, apesar de seus avanços, a aplicação da IA na RD ainda enfrenta barreiras, como a falta de dados rotulados diversificados, questões éticas relacionadas à privacidade dos pacientes e desafios técnicos, como a explicabilidade das estruturas de IA e a interoperabilidade entre diferentes sistemas^{8,10}. Contudo, os resultados alcançados até agora destacam o potencial transformador da IA na oftalmologia, com perspectivas promissoras para ampliar o acesso e a eficiência nos cuidados com a saúde ocular^{14,18}.

Neste contexto, este estudo explora as aplicações da IA no rastreio da RD, aborda avanços recentes, desafios e perspectivas futuras¹³. A proposta é reunir, analisar e sintetizar os avanços tecnológicos, os métodos empregados, os resultados obtidos e os desafios enfrentados no desenvolvimento e aplicação de sistemas baseados em IA¹². Para isso busca-se responder às seguintes questões norteadoras: 1) Quais são as principais tecnologias de IA aplicadas ao rastreio da RD?; 2) Quais são os resultados obtidos por esses modelos e os principais desafios

enfrentados na prática clínica?; e 3) Quais são as perspectivas e diretrizes para a integração efetiva dessas tecnologias em ambientes de cuidado em saúde? Assim, o presente estudo pretende contribuir com uma visão atualizada e indicar lacunas para futuras pesquisas¹⁵.

Métodos

O presente estudo, a fim de responder às questões propostas, utilizou uma abordagem metodológica de revisão integrativa da literatura, com o objetivo de identificar, analisar e sintetizar pesquisas relevantes sobre o uso de IA no rastreio da RD. A revisão foi conduzida em bases de dados eletrônicas renomadas, como PubMed, SciELO e Google Acadêmico, o que garantiu uma busca abrangente e criteriosa que abordasse os avanços mais recentes no campo.

A pesquisa bibliográfica foi realizada com o uso de termos específicos, como *diabetic retinopathy*, *artificial intelligence in ophthalmology* e *deep learning for medical imaging*. Esses descritores foram combinados por meio do operador booleano AND para tornar a pesquisa mais precisa. Destaca-se que o levantamento foi limitado a artigos publicados entre 2020 e 2024, nos idiomas inglês, português e espanhol. Para refinar os resultados, alguns critérios de inclusão foram definidos: estudos originais que investigaram o uso de IA na detecção da RD. Além disso, consideraram-se apenas artigos com acesso integral e gratuito para análise.

Por outro lado, os critérios de exclusão eliminaram revisões de literatura, editoriais e resumos de congressos. Trabalhos que não abordavam diretamente o uso de IA no rastreio da RD ou que se concentravam em outras patologias oftalmológicas também foram excluídos, assim como estudos publicados antes de 2020 ou duplicados entre as bases de dados.

A seleção inicial resultou em 450 artigos identificados nas bases pesquisadas. O processo de rastreio e seleção dos estudos está representado no fluxograma (*cf.* Figura 1). Após a aplicação dos critérios de inclusão e exclusão, 20 estudos foram considerados elegíveis para análise detalhada. Informações-chave foram extraídas de cada estudo, como o tipo de algoritmos utilizado, métricas de desempenho, viabilidade clínica e os desafios associados ao uso da IA no rastreio da RD. A avaliação da qualidade metodológica dos estudos foi realizada com base em critérios como rigor científico, relevância clínica e alinhamento com os objetivos da pesquisa.

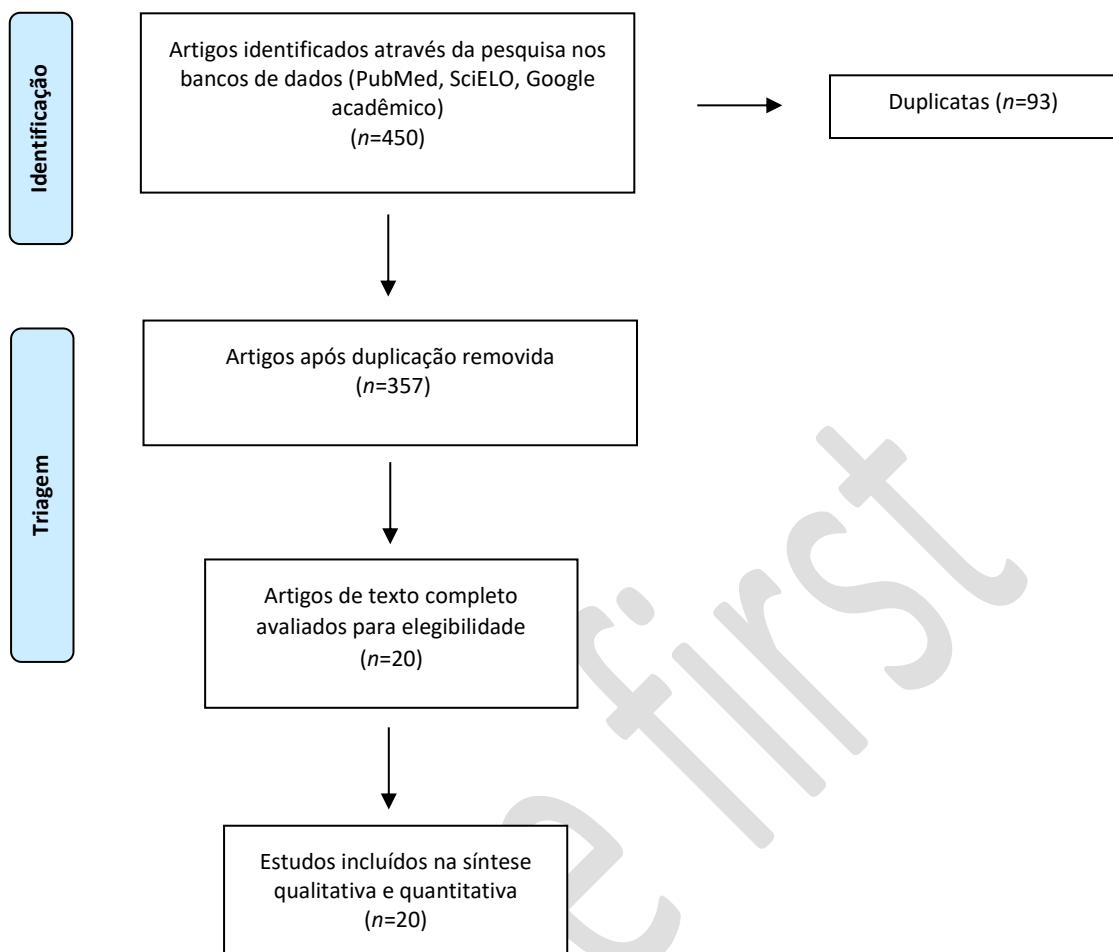


Figura 1. Fluxograma de seleção dos estudos.

Revisão

IA no contexto geral da medicina

A IA tem se destacado como uma ferramenta essencial na medicina moderna, que tem revolucionado campos como diagnóstico, tratamento e pesquisa. Tecnologias baseadas em *deep learning* e aprendizagem por transferência permitem análises rápidas e precisas de dados complexos, como imagens médicas, históricos de pacientes e resultados laboratoriais^{9,12}. Além disso, um outro estudo ressalta que sistemas de IA são amplamente utilizados para prever desfechos clínicos, personalizar tratamentos e monitorar a evolução de doenças¹⁹.

Esse avanço tem impactado diretamente a saúde pública, especialmente ao ampliar o acesso ao diagnóstico em regiões com infraestrutura limitada¹⁸. A aplicação de IA também tem possibilitado a integração de dados clínicos complexos para decisões mais assertivas, reduzindo erros e otimizando o tempo no atendimento médico¹⁴.

Inteligência Artificial na oftalmologia

Na oftalmologia, a IA tem revolucionado o diagnóstico e o tratamento de diversas condições oculares, como glaucoma, degeneração macular relacionada à idade (DMRI) e RD²⁰. Também um estudo de 2022 revela que ferramentas baseadas em IA são capazes de processar imagens de fundo de olho, tomografia de coerência óptica (OCT, do inglês *optical coherence tomography*) e outros exames oftalmológicos com alta precisão, muitas vezes superando a análise manual em termos de rapidez e confiabilidade¹⁶.

Sistemas como *Google AI for Retinal Diseases* e *DeepMind* têm sido utilizados para identificar sinais precoces de doenças oculares, o que permite a intervenção antes que os danos se tornem irreversíveis²¹. Ademais, plataformas de rastreio automatizada baseadas em IA, como *EyeArt* e *IDx-DR*, já aprovadas por órgãos reguladores como a *Food and Drug Administration*, são amplamente empregadas em programas de rastreio populacional, o que amplia o acesso ao diagnóstico em regiões remotas¹⁷. Outro fator que permite a ampliação do alcance do cuidado ocular é a integração da IA a dispositivos portáteis e *smartphones* para a realização de exames oftalmológicos, o que facilita a adoção dessas ferramentas em diferentes cenários clínicos¹⁸.

Inteligência Artificial na retinopatia diabética

A IA tem desempenhado um papel fundamental no diagnóstico e manejo da RD, uma das principais causas de cegueira evitável²². Sistemas de IA especializados em RD utilizam algoritmos avançados, como CNNs, para identificar lesões específicas, como microaneurismas, hemorragias e exsudados, em imagens de fundo de olho^{14,19}. Além disso, a IA permite a classificação dos diferentes estágios da RD, auxiliando os profissionais de saúde a priorizar os casos mais graves e planejar tratamentos de forma mais eficaz²¹.

Algoritmos de aprendizagem por transferência e aprendizagem auto-supervisionada também têm sido explorados para superar a escassez de dados rotulados, de forma a possibilitar que os sistemas de IA sejam treinados com mais eficiência^{9,12}.

A integração da IA com dispositivos móveis e plataformas baseadas em nuvem tem ampliado o acesso ao diagnóstico da RD em áreas rurais e subatendidas¹⁸. Esses avanços não apenas melhoram a detecção precoce da doença, mas também reduzem os custos associados ao rastreio e ao tratamento; assim, a IA se torna uma solução viável e escalável para combater a cegueira relacionada à diabetes⁴⁻⁵.

Resultados

Inteligência Artificial como ferramenta de rastreio

Tradicionalmente, o rastreio da RD depende de exames realizados por oftalmologistas que utilizam imagens de fundo de olho¹⁶. No entanto, esses procedimentos enfrentam limitações relacionadas ao tempo, custo e disponibilidade de especialistas qualificados, o que dificulta atender à crescente demanda por triagens e detecções precoces^{13,23}. Nesse cenário, a IA destaca-se como uma solução promissora que automatiza o rastreio de RD e reduz a subjetividade associada à análise manual de imagens^{12,19}.

Um dos principais avanços foi o uso de CNNs para a análise de imagens de fundo de olho²⁰. Estruturas como *ResNet*, *DenseNet* e *Inception* foram amplamente utilizadas em tarefas de classificação de imagens, apresentando evidências favoráveis de desempenho em precisão e sensibilidade²². Por exemplo, a *ResNet-50* revisada foi projetada para melhorar a calibração dos módulos e evitar problemas como *overfitting*, alcançando uma precisão de 83,95% no treinamento e 74,32% no teste¹⁹. Além disso, técnicas de segmentação como a *U-Net* têm sido empregadas para identificar características específicas, como microaneurismas e exsudados, que são indicativos dos diferentes estágios da RD^{16,22}. Adicionalmente, a aplicação de plataformas como *YOLOv3* demonstra eficiência em identificar múltiplas lesões em diferentes estágios da doença, o que reforça a capacidade da IA em analisar dados complexos¹⁸.

Metodologias mais recentes, como o uso de transformadores visuais (*Vision Transformers*), estão a ser investigadas para superar desafios como desequilíbrio de classes e necessidade de grandes conjuntos de dados rotulados^{9,15}. Essas abordagens têm o potencial de melhorar não apenas a identificação de lesões, mas também a classificação precisa dos estágios da RD, desde os mais leves até os proliferativos^{4,12}.

Arquiteturas baseadas em aprendizagem por transferência foram utilizadas para superar a escassez de dados rotulados¹⁴. Redes como *InceptionV3* e *AlexNet* têm sido pré-treinadas em grandes conjuntos de dados e, posteriormente, ajustadas para tarefas específicas de classificação de RD²².

Entre os desafios enfrentados por essas estruturas destacam-se a necessidade de maior explicabilidade das abordagens e a complexidade computacional associada a arquiteturas profundas¹⁷. Estratégias como mapas de atenção e visualizações *Grad-CAM* têm sido exploradas para fornecer *insights* sobre as decisões das arquiteturas, enquanto abordagens de regularização ajudam a mitigar os custos computacionais^{12,19}. Adicionalmente, métodos auto-supervisionados, como o *Self-Supervised Fuzzy Clustering Network* (SFCN), têm demonstrado potencial em extrair características relevantes sem a necessidade de grandes quantidades de dados rotulados^{4,9}.

Tecnologias de segmentação e classificação

Os resultados obtidos com tecnologias baseadas em IA na detecção de RD são promissores, o que evidencia o potencial dessas abordagens para superar limitações dos métodos tradicionais²². Por exemplo, no estudo realizado por Alyoubi, Abulkhair e Shalash²⁰, um sistema baseado em CNNs integrado ao modelo *YOLOv3* para localização de lesões alcançou uma precisão de 89% na classificação dos cinco estágios da RD, com sensibilidade de 89% e especificidade de 97,3% ao identificar microaneurismas, exsudados e hemorragias. Esses resultados destacam a habilidade das CNNs em lidar com tarefas desafiadoras de segmentação e classificação de lesões em imagens de retina¹⁶.

Um dos estudos evidenciou que o emprego de transformadores visuais (*vision transformers*) tem demonstrado eficácia no enfrentamento de desafios como o desequilíbrio de classes em grandes conjuntos de dados⁹. Abordagens baseadas nesses transformadores conseguem identificar padrões locais e globais em imagens, o que favorece uma maior generalização e robustez^{15,17}. Essa característica é especialmente útil em cenários com alta variabilidade nos dados de treinamento e validação¹⁴.

Outro progresso relevante foi a aplicação da aprendizagem por transferência, que viabiliza o uso de redes pré-treinadas em grandes bases de dados e posterior adaptação para tarefas específicas⁴. Também um dos estudos mostrou que a integração entre o *InceptionV3* e técnicas de segmentação como *U-Net* resultou em uma precisão média superior a 94% na detecção automática de RD em conjuntos de dados como *EyePACS-1* e *Messidor-2*²².

Apesar do progresso, alguns desafios permanecem. A interpretabilidade dos sistemas ainda é limitada, o que dificulta sua adoção clínica⁹. Para enfrentar esse obstáculo, mapas de calor como o *Grad-CAM* são usados para indicar áreas da retina que influenciam as classificações, o que promove maior transparência^{13,19}. Além disso, a alta demanda computacional das redes profundas limita sua aplicação em locais com infraestrutura restrita, como clínicas de áreas rurais⁵.

Os avanços mais recentes incluem o uso de GANs para criar imagens sintéticas de retina, o qual proporciona a diversidade de dados para treinamento¹². Essa inovação pode reduzir a dependência de grandes bases de dados rotuladas, uma das principais barreiras na aplicação da IA à RD¹⁶.

Esses resultados evidenciam que, apesar dos desafios, a integração de IA no rastreio e detecção da RD continua a avançar e proporciona soluções mais precisas, acessíveis e escaláveis¹⁸. Tecnologias emergentes prometem melhorar ainda mais a eficácia e o alcance desses sistemas nos próximos anos⁷.

Apesar do progresso significativo obtido com o uso de tecnologias de IA na detecção da RD, vários desafios e limitações precisam ser resolvidos para possibilitar uma adoção clínica mais ampla e eficaz²².

Um dos principais desafios é a explicabilidade dos sistemas baseados em *deep learning*. Muitas técnicas utilizadas atualmente, como CNNs e transformadores visuais, operam como “caixas-pretas”, dificultando a compreensão dos resultados por especialistas em oftalmologia^{17,19}. Métodos como *Grad-CAM* e mapas de atenção têm sido desenvolvidos para promover maior transparência, que destacam áreas específicas da retina que contribuem para as classificações, mas essas técnicas ainda carecem de validação clínica e padronização robusta¹²⁻¹³.

Outro obstáculo relevante é a dependência de grandes volumes de dados rotulados para treinamento. Embora abordagens como aprendizagem por transferência e redes auto-supervisionadas auxiliem na mitigação desse problema, a falta de dados diversificados e equilibrados continua sendo um entrave^{9,15}. Estudos apontam que muitos sistemas demonstram menor desempenho quando aplicados a diferentes populações ou equipamentos daqueles usados no treinamento, evidenciando a limitada generalização dos algoritmos^{18,22}.

Além disso, a complexidade computacional das arquiteturas profundas restringe sua implementação em ambientes com infraestrutura limitada, como clínicas rurais ou países em desenvolvimento¹⁴. Estratégias como compressão e regularização de modelos, bem como o desenvolvimento de arquiteturas mais leves, têm sido exploradas para enfrentar esse problema. No entanto, essas soluções frequentemente resultam em perda da precisão dos resultados^{19,23}.

A interoperabilidade entre diferentes sistemas de IA e dispositivos de captura de imagem também apresenta desafios significativos. A ausência de padronização nos formatos de dados, nas resoluções de imagem e nas condições de iluminação pode causar inconsistências nos resultados e dificultar a integração desses sistemas nos fluxos de trabalho clínico^{16,20}. Essa questão é especialmente crítica em contextos onde múltiplas instituições utilizam diferentes soluções tecnológicas⁴.

Questões éticas e regulatórias representam outro conjunto de desafios a serem superados. A proteção da privacidade dos dados dos pacientes, a identificação e mitigação de vieses algorítmicos e a definição de responsabilidades em casos de falhas diagnósticas realizados pelos sistemas de IA são tópicos que exigem atenção antes que essas tecnologias possam ser amplamente implementadas^{15,17}.

Portanto, embora os avanços no uso de IA para a RD sejam promissores é essencial que esforços contínuos sejam direcionados para superar essas limitações. Investimentos em pesquisa e desenvolvimento serão fundamentais para garantir que essas ferramentas sejam

confiáveis, acessíveis e capazes de atender às diversas necessidades clínicas em diferentes contextos⁵.

Desafios e direções futuras

A integração da IA no rastreio da RD promove transformações significativas no campo da oftalmologia clínica ao oferecer a possibilidade de triagens em pontos de atendimento, o que reduz o tempo e o custo associados aos métodos tradicionais²⁰.

Além disso, a IA tem vindo a ser empregada para monitorar a progressão da doença e personalizar tratamentos. Arquiteturas de *deep learning*, como as baseadas em CNNs, são capazes de identificar alterações sutis nas imagens da retina, o que possibilita ajustes nos tratamentos, como injeções que inibem o crescimento de vasos anormais ou procedimentos a laser, antes que ocorra um dano irreversível à visão¹⁸⁻¹⁹. Ferramentas como *Grad-CAM* também ajudam a aumentar a confiança do médico ao fornecer explicações visuais sobre a classificação dos sistemas de IA¹²⁻¹³.

No futuro espera-se que os avanços em GANs e aprendizagem auto-supervisionada melhorem ainda mais as capacidades dessas tecnologias¹⁴. As GANs, por exemplo, podem ser usadas para gerar dados sintéticos de retina, o que amplia o escopo de treinamento das arquiteturas de IA e permitem maior generalização em diferentes populações e equipamentos²³. Já as técnicas de aprendizagem auto-supervisionada, como *Self-Supervised Fuzzy Clustering Network* (SFCN), podem reduzir significativamente a dependência de dados rotulados, o que torna os sistemas mais acessíveis em contextos de recursos limitados^{12,15}.

Outro potencial futuro está na integração de sistemas baseados em IA em dispositivos móveis ou portáteis, o que permite exames rápidos e rastreios preliminares diretamente em comunidades isoladas ou em ambientes clínicos de baixo custo²³. A combinação de IA com Internet das Coisas (IoT) pode proporcionar um monitoramento contínuo e remoto da saúde ocular dos pacientes e reduz o risco de complicações graves^{12,16}.

Embora ainda existam desafios como questões éticas e regulatórias, as aplicações clínicas de IA na RD representam um avanço notável no cuidado oftalmológico¹⁷. À medida que as tecnologias continuam a evoluir espera-se que essas ferramentas se tornem cada vez mais integradas ao fluxo de trabalho clínico e transformem a forma como a RD é detectada e gerenciada globalmente^{5,20}.

Para sintetizar as principais técnicas de IA identificadas nesta revisão, a Tabela 1 apresenta um resumo comparativo com suas especificidades, níveis de desempenho, vantagens e limitações no contexto da detecção automatizada da RD.

Tabela 1. Técnicas de IA aplicadas à detecção da RD

Técnica / Arquitetura	Especificidades	Sensibilidade / Acurácia	Principais vantagens	Principais limitações
CNN (<i>Convolutional Neural Network</i>)	Usa filtros convolucionais para extrair padrões espaciais das imagens da retina	85-94% (varia por dataset)	Boa acurácia em imagens RGB; fácil integração com outras camadas	Pode sofrer <i>overfitting</i> ; sensível a ruídos
ResNet-50	Rede profunda com blocos residuais que evitam o desaparecimento do gradiente	Até 95% (em Messidor e EyePACS)	Excelente desempenho em profundidade; usada com <i>Transfer Learning</i>	Exige mais recursos computacionais
EfficientNet	Arquitetura otimizada em profundidade, largura e resolução	>93% (dependendo da base)	Alta performance com menos parâmetros	Menor interpretabilidade
U-Net	Voltada para segmentação (e.g., vasos, lesões) com arquitetura em forma de U	Até 90% na segmentação de vasos	Alta resolução espacial na saída	Menos eficaz para classificação global da imagem
YOLO (<i>You Only Look Once</i>)	Detecta e classifica múltiplas regiões em uma única passada	Alta sensibilidade em lesões	Rápido e eficiente para detecção localizada	Pode perder precisão em imagens de baixa qualidade
Transformadores Visuais (ViT, Swin)	Aplicam mecanismos de atenção em toda a imagem, capturando dependências espaciais globais	>90% em testes recentes	Aprendem contextos mais amplos; adaptáveis a diversas tarefas	Muito dependentes de grandes volumes de dados rotulados
GANs (<i>Generative Adversarial Networks</i>)	Geram imagens sintéticas para aumentar bases de dados e reduzir viés	N/A (suporte à IA, não classifica)	Melhoram generalização; ampliam datasets minoritários	Complexos de treinar; risco de imagens irreais

Fonte: Elaborado pelo autor com base na literatura^{8-13,17}.

Conclusão

Este estudo analisou o impacto da IA no rastreio automatizado da RD, com destaque em avanços recentes, limitações e potenciais aplicações clínicas. As tecnologias como CNNs, transformadores visuais e técnicas de aprendizagem por transferência contribuem para uma detecção mais precoce, precisa e acessível da doença, especialmente em contextos com escassez de especialistas.

Alguns modelos, como EyeArt e IDx-DR, demonstraram alto desempenho em rastreios populacionais. No entanto, desafios relevantes persistem, como a baixa generalização de alguns modelos – frequentemente associada ao *overfitting*, em que o sistema se ajusta excessivamente aos dados de treinamento, o que prejudica seu desempenho em novos conjuntos de dados. Além disso, a falta de explicabilidade, a necessidade de padronização dos dados, a dependência de grandes volumes de imagens rotuladas e as questões éticas, como privacidade e viés algorítmico, seguem como barreiras para a ampla adoção clínica.

Conclui-se que, embora a aplicação da IA no rastreio da RD represente um avanço significativo na oftalmologia, com o potencial de transformar o manejo da doença globalmente, sua consolidação exige esforços contínuos em pesquisa e desenvolvimento ético, a fim de superar os desafios atuais e garantir que essas tecnologias tenham eficácia, acessibilidade e segurança no cuidado oftalmológico.

Agradecimentos. À Universidade Evangélica de Goiás pelo suporte institucional e financeiro, ao Programa de Bolsas de Inovação para o Desenvolvimento de Produtos Tecnológicos da UniEVANGÉLICA (PBIDPT), por meio do projeto SOFTWARE – UNIRASTREIO DA RETINOPATIA DIABÉTICA, submetido ao Edital nº 28/2024 – Modalidade IDT&I-PBIDPT, e ao apoio financeiro da Fundação Nacional de Desenvolvimento do Ensino Superior Particular (Funadesp), que foram essenciais para a execução e conclusão deste trabalho.

Contributo dos autores. GBSB contribuiu na construção da parte teórica e prática do papel da Inteligência Artificial no contexto do trabalho; LFV e EEMJ contribuíram na construção da parte jurídica do trabalho; IVB, CSO e SÃO contribuíram na construção da parte de medicina do trabalho; SDS contribuiu na construção da parte histórica e social do trabalho.

Referências bibliográficas

1. Bortoli JQ, Silber PC, Picetti E, Silva CF, Pakter HM. Retinografia como forma de rastreio de retinopatia diabética em hospital terciário do Sistema Único de Saúde [Color retinography as a means of screening for diabetic retinopathy in the tertiary hospital of Unified Health System]. Rev Bras Oftalmol. 2022;81:e0057. Portuguese
2. Sheng B, Chen X, Li T, Ma T, Yang Y, Bi L, et al. An overview of artificial intelligence in diabetic retinopathy and other ocular diseases. Front Public Health. 2022;10:971943.
3. Galvão FM, Silva YP, Resende MI, Barbosa FR, Martins TA, Carneiro LB. Prevalência e fatores de risco para retinopatia diabética em pacientes diabéticos atendidos por demanda espontânea: um estudo transversal [Prevalence and risk factors of diabetic retinopathy in patients with diabetes seen by unscheduled demand: a cross-sectional study]. Rev Bras Oftalmol. 2021;80(3):e0006. Portuguese
4. Jabbar MK, Yan J, Xu H, Ur Rehman Z, Jabbar A. Transfer learning-based model for diabetic retinopathy diagnosis using retinal images. Brain Sci. 2022;12(5):535. Erratum in: Brain Sci. 2024;14(8):777.
5. Guerra DK, Silva WM, Calixto TB, Menezes PH, Silveira NR, Ferreira MA, et al. Estratégias de prevenção para retinopatia diabética em pacientes com diabetes tipo 2 [Prevention

- strategies for diabetic retinopathy in patients with type 2 diabetes]. Rev Centro Pesq Avançadas Qual Vida. 2024;16(2). Portuguese
6. Cruvinel ME, Macêdo SE, Carvalho EA, Peres JC, Rodrigues IS, Ferreira JP, et al. Exames disponíveis para o diagnóstico da retinopatia diabética: uma revisão [Available tests for diagnosis of diabetic retinopathy: a review]. Braz J Health Rev. 2023;6(3):9346-53. Portuguese
 7. Wu JH, Liu TY, Hsu WT, Ho JH, Lee CC. Performance and limitation of machine learning algorithms for diabetic retinopathy screening: meta-analysis. J Med Internet Res. 2021;23(7):e23863.
 8. Carvalho BF, Carvalho LF, Takahashi IM, Libânia PG, Vieira GG, Carvalho RN. O uso da inteligência artificial para diagnóstico da retinopatia diabética: uma revisão narrativa [The use of artificial intelligence for diagnosis of diabetic retinopathy: a narrative review]. Rev Med Minas Gerais. 2022;32 Suppl 01:S42-5. Portuguese
 9. Luo X, Wang W, Xu Y, Lai Z, Jin X, Zhang B, et al. A deep convolutional neural network for diabetic retinopathy detection via mining local and long-range dependence. CAAI Trans Intell Technol. 2024;9(1):153-66.
 10. Grauslund J. Diabetic retinopathy screening in the emerging era of artificial intelligence. Diabetologia. 2022;65(9):1415-23.
 11. Li S, Zhao R, Zou H. Artificial intelligence for diabetic retinopathy. Chin Med J (Engl). 2021;135(3):253-60.
 12. Arwany MZ, Sahyoun AH, Yaqub M. Deep learning techniques for diabetic retinopathy classification: a survey. IEEE Access. 2022;10:28642-53.
 13. Fayyaz AM, Sharif MI, Azam S, Karim A, El-Den J. Analysis of diabetic retinopathy (DR) based on the deep learning. Information. 2023;14(1):30.
 14. Quellec G, Al Hajj H, Lamard M, Conze PH, Massin P, Cochener B. ExplAIIn: explanatory artificial intelligence for diabetic retinopathy diagnosis. Med Image Anal. 2021;72:102118.
 15. Haq NU, Waheed T, Ishaq K, Hassan MA, Safie N, Elias NF, et al. Computationally efficient deep learning models for diabetic retinopathy detection: a systematic literature review. Artif Intell Rev. 2024;57:309-47.
 16. Lim JI, Regillo CD, Sadda SR, Ipp E, Bhaskaranand M, Ramachandra C, et al. Artificial Intelligence detection of diabetic retinopathy: subgroup comparison of the EyeArt system with ophthalmologists' dilated examinations. Ophthalmol Sci. 2022;3(1):100228.
 17. Senapati A, Tripathy HK, Sharma V, Gandomi AH. Artificial intelligence for diabetic retinopathy detection: a systematic review. Inform Med Unlocked. 2024;45:101445.

18. Oliveira LE, Silva MC, Santiago RV, Benevides CA, Cunha CC, Matos AG. Diagnóstico da retinopatia diabética por inteligência artificial por meio de smartphone [Diagnosis of diabetic retinopathy by artificial intelligence using smartphone]. Rev Bras Oftalmol. 2024;83:e0006. Portuguese
19. Lin CL, Wu KC. Development of revised ResNet-50 for diabetic retinopathy detection. BMC Bioinformatics. 2023;24(1):157.
20. Alyoubi WL, Abulkhair MF, Shalash WM. Diabetic retinopathy fundus image classification and lesions localization system using deep learning. Sensors (Basel). 2021;21(11):3704.
21. Alqaralleh BA, Aldhaban F, Abukaraki A, AlQaralleh EA. Evolutionary intelligence and deep learning enabled diabetic retinopathy classification model. Comp Mater Contin. 2022;73(1):87-101.
22. Bilal A, Zhu L, Deng A, Lu H, Wu N. AI-based automatic detection and classification of diabetic retinopathy using U-Net and deep learning. Symmetry. 2022;14(7):1427.
23. Thanekachalam V, Kavitha MG, Sivamurugan V. Diabetic retinopathy diagnosis using interval neutrosophic segmentation with deep learning model. Comp Syst Sci Eng. 2023;44(3):2129-45.

Conflito de interesses

Os autores declaram não possuir quaisquer conflitos de interesse.

Artigo recebido em 03.07.2025 e aprovado em 09.09.2025