

Diagnóstico da retinopatia diabética por inteligência artificial por meio de *smartphone*

Diagnosis of diabetic retinopathy by artificial intelligence using *smartphone*

Luiz Eduardo Silva de Oliveira¹, Marcelo Colares da Silva², Rhuan Victor Crescêncio de Santiago²,
Cilis Aragão Benevides², Caio César Henrique Cunha², Alexis Galeno Matos¹

¹ Fundação Leiria de Andrade, Fortaleza, CE, Brasil.

² WDA Tecnologia & Inovação, Fortaleza, CE, Brasil.

Como citar:

Oliveira LE, Silva MC, Santiago RV, Benevides CA, Cunha CC, Matos AG. Diagnóstico da retinopatia diabética por inteligência artificial por meio de *smartphone* Rev Bras Oftalmol. 2024;83:e0006.

doi:

<https://doi.org/10.37039/1982.8551.20240006>

Descritores:

Diabetes; Retinopatia diabética; Inteligência artificial; Smartphone; Deep learning

Keywords:

Diabetes; Diabetic retinopathy; Artificial intelligence; Smartphone; Deep learning

Recebido:

5/6/2023

Aceito:

23/11/2023

Autor correspondente:

Alexis Galeno Matos, PhD
Hospital de Olhos Leiria de Andrade
Rua Rocha Lima, 1.140 – Aldeota
CEP 60135-000 – Fortaleza, CE, Brasil
E-mail: alexisgaleno@gmail.com

Instituição de realização do trabalho:

Fundação Leiria de Andrade/ WDA
Technology and Innovation; Fortaleza, CE,
Brasil.

Fonte de auxílio à pesquisa:

não financiado.

Conflitos de interesse:

não há conflitos de interesses.



Copyright ©2024

RESUMO

Objetivo: Obter imagens de fundoscopia por meio de equipamento portátil e de baixo custo e, usando inteligência artificial, avaliar a presença de retinopatia diabética.

Métodos: Por meio de um *smartphone* acoplado a um dispositivo com lente de 20D, foram obtidas imagens de fundo de olhos de pacientes diabéticos; usando a inteligência artificial, a presença de retinopatia diabética foi classificada por algoritmo binário.

Resultados: Foram avaliadas 97 imagens da fundoscopia ocular (45 normais e 52 com retinopatia diabética). Com auxílio da inteligência artificial, houve acurácia diagnóstica em torno de 70 a 100% na classificação da presença de retinopatia diabética.

Conclusão: A abordagem usando dispositivo portátil de baixo custo apresentou eficácia satisfatória na triagem de pacientes diabéticos com ou sem retinopatia diabética, sendo útil para locais sem condições de infraestrutura.

ABSTRACT

Introduction: To obtain funduscopy images through portable and low-cost equipment using artificial intelligence to assess the presence of DR.

Methods: Fundus images of diabetic patients' eyes were obtained by using a smartphone coupled to a device with a 20D lens. By using artificial intelligence (AI), the presence of DR was classified by a binary algorithm.

Results: 97 ocular funduscopy images were evaluated (45 normal and 52 with DR). Through AI diagnostic accuracy around was 70% to 100% in the classification of the presence of DR.

Conclusion: The approach using a low-cost portable device showed satisfactory efficacy in the screening of diabetic patients with or without diabetic retinopathy, being useful for places without infrastructure conditions.

INTRODUÇÃO

A variedade de complicações relacionadas ao diabetes é alta e crescente em todos os países, sendo principalmente causada pelo aumento da prevalência da obesidade.⁽¹⁾ Estima-se que tenhamos no mundo cerca de 537 milhões de pacientes com *diabetes mellitus* (DM), além de aumento para 700 milhões até 2045.⁽²⁾ No Brasil, a doença atinge 9,2% da população.⁽³⁾

A retinopatia diabética (RD) é a complicação mais frequente da DM e uma das principais causas de cegueira adquirida na população em idade ativa. É uma doença crônica progressiva da microvasculatura retiniana.⁽⁴⁾ O número de pacientes com RD é aproximadamente 93 milhões no mundo, devendo aumentar para 191 milhões até 2030.⁽⁵⁾ Destes, 10% desenvolverão RD grave com risco de dano na visão, pois menos de 60% dos pacientes diabéticos são submetidos a exames oftalmológicos regulares em intervalos recomendados pelas diretrizes devido ao alto custo e à baixa acessibilidade dos serviços oftalmológicos.^(6,7)

O início da RD é insidioso, e a maioria dos pacientes tem um longo período assintomático. Durante esse tempo, as lesões podem ser facilmente identificadas por exame de fundo de olho ou fotografia da retina. O diagnóstico e tratamento da RD na fase inicial pode alcançar bons resultados na prevenção do desenvolvimento da doença e reduzir significativamente a taxa de cegueira.^(8,9) Porém, em muitas regiões de países em desenvolvimento, a triagem é falha, devido à falta de recursos, de educação e profissionais capacitados, levando ao diagnóstico somente em estágio avançado e com danos irreversíveis na visão.⁽¹⁰⁾

O desenvolvimento da tecnologia da informação atingiu todos os aspectos da vida moderna. Na oftalmologia, o desenvolvimento da *deep learning* e dos programas de inteligência artificial (IA) tem sido aplicado em imagens para identificar doenças oftalmológicas como glaucoma, degeneração macular relacionada à idade e a RD.^(11,12) No entanto, a maioria dos sistemas atuais é de alto custo, pois usa imagens de retinógrafos ou tomografia de coerência óptica (OCT).

Visando otimizar o diagnóstico e o encaminhamento para centro especializados objetivamos obter imagens de fundoscopia por meio de equipamento portátil e de baixo custo e, usando IA, avaliar a presença de retinopatia diabética.

MÉTODOS

Estudo transversal, observacional, descritivo, baseado em dados obtidos a partir de pacientes em consulta oftalmológica em hospital de referência em oftalmologia.

Foi aprovado em Comitê de Ética em Pesquisa sob parecer 5.441.784 e seguiu todas as normas éticas necessárias.

Coleta e fonte de dados

Modulo de captura

Com o Laboratório de Processamento de Imagens, Sinais e Computação Aplicada (Lapisco), foi criado um protótipo em impressora 3D de adaptador para *smartphone* (modelo iPhone 8s, Apple) usando uma lente de 20D e configurada na distância focal para obter imagens fundoscópicas de olhos em midríase medicamentosa realizada com instilação de uma gota de tropicamida a 1%, três vezes, com intervalo de 5 minutos entre as gotas (Figura 1).



Figura 1. Dispositivo portátil para imagens da retina.

Modulo de hipótese diagnóstica

Um módulo de hipótese diagnóstica foi desenvolvido em parceria com a *WDA Technology and Innovation (Portable Diavision)*, baseada em módulo de hipótese diagnóstica binária (ausência ou presença de RD) e por meio de *deep transfer learning*, com uso de imagens retinográficas de pacientes normais e com RD, além do *dataset* MESSIDOR.

Para realizar o diagnóstico de uma imagem de retinografia, é necessário realizar duas etapas. A primeira etapa consiste na extração de características de elementos mais relevantes na imagem (no presente estudo, foram utilizadas CNNs (Redes Neurais Convolucionais) para fazer essa extração). A segunda etapa consiste em usar um conjunto significativo das características extraídas para treinar um algoritmo de aprendizado de máquina. Isso permite que o algoritmo aprenda padrões e faça diagnósticos futuros.

Durante os experimentos realizados, diferentes combinações de CNNs e algoritmos de aprendizado de máquina foram testadas com o objetivo de detectar a presença ou ausência da retinopatia diabética. A métrica usada para avaliação foi a precisão ou acurácia na classificação das imagens da retinografia. Em seguida, os resultados obtidos em todas as combinações foram analisados para selecionar aquela que obteve os melhores resultados.

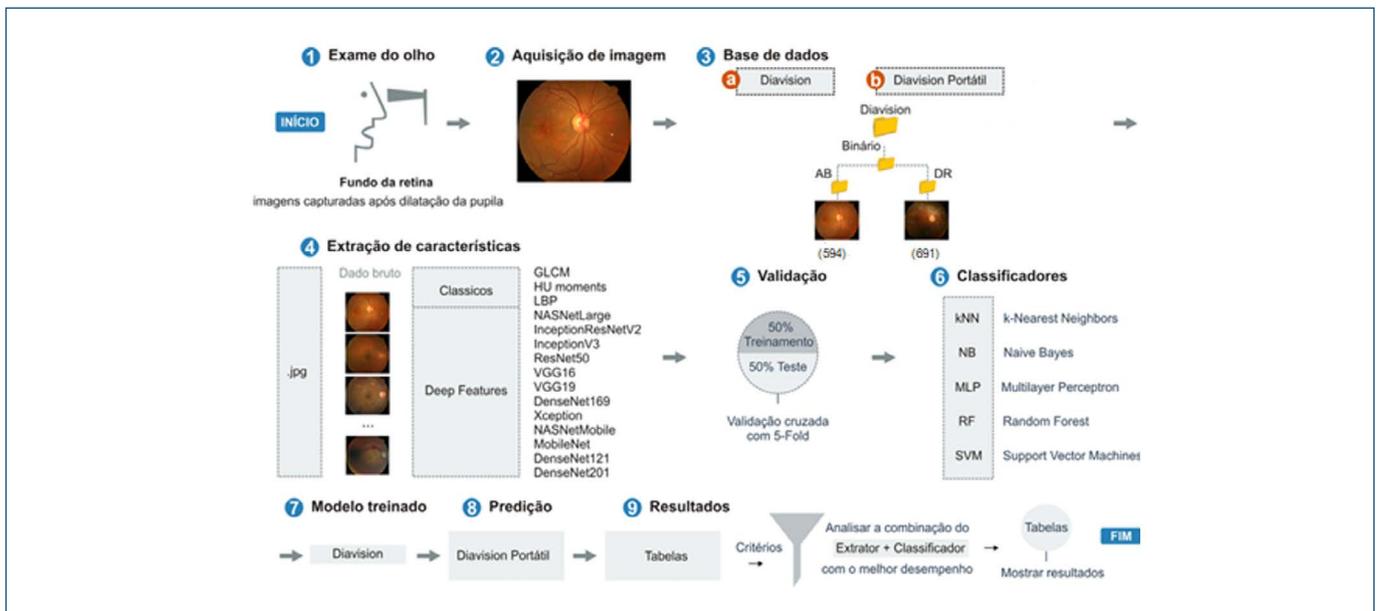


Figura 2. Fluxograma da metodologia adotada.

Os métodos de aprendizagem de máquina avaliados durante o projeto foram Bayes, *Multilayer Perceptron* (MLP), *Nearest Neighbor* (NN), *Random Forest*, *Support Vector Machines* (SVM).

O fluxograma da metodologia adotada teve nove etapas: (1) Aquisição de Imagens utilizando o retinógrafo e o equipamento *Portable Diavision*; (2) exemplo de imagens para criar duas bases de dados: *diavision* e *diavision portátil*; (3) descrição das bases de dados utilizadas; (4) extração de características com três extratores clássicos e 12 arquiteturas com redes neurais (CNN); (5) método de validação utilizado; (6) avaliação com cinco métodos de aprendizagem de máquina; (7) modelos obtidos após o treinamento com as bases de dados *Diavision* e *Messor*; (8) previsão a partir de imagens da base de dados *Portable Diavision*; (9) avaliação dos resultados em todos os conjuntos de dados (Figura 2).

Variáveis do estudo

O conjunto de dados foi avaliado em abordagens binárias, em que dois diagnósticos foram apresentados: ausência e presença da RD. Por meio da abordagem binária, o objetivo foi detectar a doença pelo exame oftalmológico, identificando lesões, como hemorragias ou exsudatos.

Na comparação com especialista, uma variável quantitativa contínua expressa a compatibilidade de respostas quando se compara o resultado da classificação pela inteligência artificial com a avaliação de especialista.

O algoritmo é uma variável qualitativa nominal que estabelece o algoritmo, utilizado para análise da série de imagens de retina em banco de dados.

Critérios de inclusão

Foram incluídas no presente estudo imagens fundoscópicas de portadores de DM tipos 1 e 2 cujo acompanhamento era regular no centro de referência.

Critérios de exclusão

Foram excluídos pacientes portadores de DM tipo 1 cujo diagnóstico se deu há menos de 3 anos, portadores de DM tipo 1 ou 2 com opacificações de meios no sistema óptico visual e que possuam quaisquer contraindicações de dilatação da pupila com medicação após avaliação oftalmológica.

Apresentação e análise dos dados

Para a análise dos dados, foram utilizados recursos de computação, por meio do processamento nos *softwares* *Biostat 5.3* e *Microsoft Excel*, todos em plataforma *Windows 10*, incorporando elementos de quadros, tabelas e gráficos.

RESULTADOS

Foram combinados os modelos de extração de características com os de *machine learning* e avaliação dos resultados de classificação binária em ausência e presença da RD em termos de métricas como acurácia.

Os resultados foram obtidos dos experimentos usando as 97 imagens de fundo ocular; destas, 45 imagens tinham RD ausente e 52 presente (Tabela 1).

Após a análise dos resultados, observamos que as abordagens utilizando extratores de *deep learning* obtiveram melhores resultados. Os modelos também foram

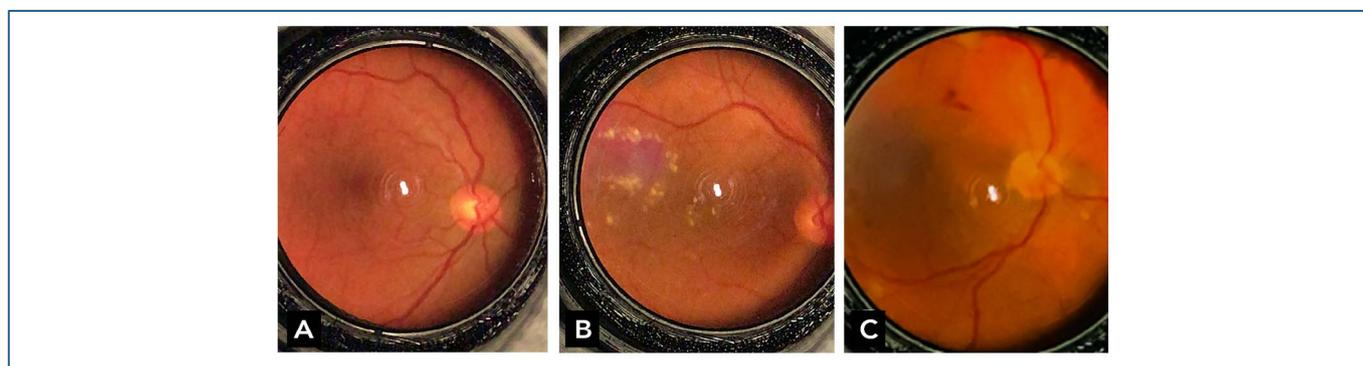


Figura 3. Imagens do fundo de olho obtida com o dispositivo. (A) Imagem normal; (B e C) imagens com alterações sugestivas de retinopatia diabética.

Tabela 1. Dados demográficos dos pacientes envolvidos no estudo

Tipo de diabetes	Sem RD		Com RD	
	Tipo 1	Tipo 2	Tipo 1	Tipo 2
Sexo (M/F), %	6 (40) / 9 (60)	17 (56,6) / 13 (43,4)	12 (57,1) / 9 (42,9)	15 (48,3) / 16 (51,7)
Idade, anos	25,3 ± 9,4	62,4 ± 8,4	30,7 ± 8,9	68,3 ± 7,4
Tempo de DM, anos	8,2 ± 2,9	6,5 ± 2,7	15,1 ± 7,6	8,25 ± 4,4

Resultados expressos por n (%)/ n total (% total) ou média ± desvio-padrão.

RD: retinopatia diabética; M/F: masculino/feminino; DM: diabetes mellitus.

Tabela 2. Testes de acurácia das imagens capturadas pelo dispositivo por meio do modelo computacional

		Treino acurácia (%)
NasNetMobile	SVM-RBF	69,16
	SVM-POLY	37,88
	SVM-LINEAR	35,88
	Randon Forest	83,47
	KNN	81,85
	Bayes	64,63
	Multilayer Perceptron	81,88

SVM: Support Vector Machines; KNN: k-Nearest Neighbor

treinados na base pública obtendo resultados satisfatórios. Os valores de acurácia ficaram em torno de 70 a 100% (Tabela 2). Logo, para a detecção da ausência e presença, podemos utilizar os modelos que utilizam *deep learning* com classificadores variados, como Random Forest, SVM.

DISCUSSÃO

O diabetes é um distúrbio metabólico debilitante e crônico que atingiu proporções epidêmicas no mundo.⁽¹³⁾ Na última década, aconteceram avanços rápidos em andamento nos campos de telecomunicações e imagens médicas, os quais abriram novos caminhos para a criação de uma estratégia de triagem eficiente para RD.⁽¹⁴⁾

Estudos mostram que a *machine learning* pode apresentar desempenho robusto em detectar diferentes categorias de RD, com sensibilidade combinada de 0,93 a 0,97 e especificidade combinada de 0,90 a 0,98.⁽⁷⁾ Porém, muitos usam equipamentos caros para obtenção das imagens da retina, com câmeras de alta qualidade. Rajalakshmi et al., usando IA (EyeArt) baseada em imagens de *smartphone*

acoplados à lâmpada de fenda mostraram 95,8% de sensibilidade e 80,2% de especificidade para detectar RD.⁽¹⁵⁾ Nosso estudo trouxe opção de baixo custo, sem uso de outro equipamento, para triagem da RD, apresentando boa eficácia e concordância com oftalmologista.

O protótipo desenvolvido é completamente portátil, leve e de fácil manuseio, com custo total aproximado de US\$1.000,00, sendo esse valor relacionado ao *smartphone* (iPhone 8s), à lente de 20D e ao dispositivo em plástico impresso em 3D. É uma opção ideal para postos de saúde ou unidades com poucos recursos de infraestrutura. O *software* instalado no *smartphone* usando a IA processa as imagens melhorando eficiência da triagem de pacientes com RD. O sistema de IA pode gerar relatórios de diagnóstico e recomendações de encaminhamento em minutos. Os pacientes que precisam de exames e tratamentos adicionais poderiam ser encaminhados, reduzindo o tempo e os custos econômicos para eles.

Nesse estudo encontramos algumas limitações. Não foi possível obter fotografias de fundo de olho de alguns pacientes com DM devido a suas pupilas pequenas ou pela má imagem qualidade por opacidade das cataratas. Para hemorragia retiniana e exsudatos causados por outras doenças, não foi possível fazer diagnóstico diferencial. O reflexo do *flash* no centro da lente de 20D foi um artefato, porém esteve presente tanto nas imagens normais quanto com RD. Também, o tamanho da amostra foi relativamente pequeno, e os pacientes eram de um único hospital.

A continuidade e o aperfeiçoamento do projeto em andamento permitem fazer avaliação multiclasse, sendo

capaz de informar a classificação da RD de acordo com nível de gravidade baseado nas lesões identificadas nas imagens.

CONCLUSÃO

Neste estudo, uma nova abordagem para detectar retinopatia diabética foi apresentada por meio de um sistema de visão computacional, usando a inteligência artificial, combinando a transferência de aprendizado com imagens de retinografias. A abordagem usando dispositivo portátil de baixo custo apresentou eficácia satisfatória na triagem de pacientes diabéticos com ou sem retinopatia diabética, usando *smartphone* para obtenção das imagens. O rastreamento de pacientes com lesões iniciais, por mais que tenhamos falso-positivos, e o encaminhamento para o especialista promoverão o tratamento mais precoce e prevenirão riscos para visão.

REFERÊNCIAS

1. Forouhi NG, Wareham NJ. Epidemiology of diabetes. *Medicine*. 2022;50(10):638-43.
2. IDF Diabetes Atlas. IDF Diabetes Atlas 2021. Tenth Edition IDF; 2021 [cited 2023 Nov 24]. Available from: <https://diabetesatlas.org/atlas/tenth-edition/>
3. Muzy J, Campos MR, Emmerick I, Silva RS, Schramm JM. Prevalence of diabetes mellitus and its complications and characterization of healthcare gaps based on triangulation of studies. *Cad Saude Publica*. 2021;37(5).
4. Porta M, Bandello F. Diabetic retinopathy: A clinical update. *Diabetologia*. 2002.
5. Zheng Y, He M, Congdon N. The worldwide epidemic of diabetic retinopathy. *Indian J Ophthalmol*. 2012;60(5):428.
6. Resnikoff S, Pascolini D, Etya'ale D, Kocur I, Pararajasegaram R, Pokharel GP, et al. Global data on visual impairment in the year 2002. *Bull World Health Organ*. 2004;82(11):844-51.
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):1-15.
8. Tan F, Chen Q, Zhuang X, Wu C, Qian Y, Wang Y, et al. Associated risk factors in the early stage of diabetic retinopathy. *Eye and Vision*. 2019;6(1):1-10.
9. He J, Cao T, Xu F, Wang S, Tao H, Wu T, et al. Artificial intelligence-based screening for diabetic retinopathy at community hospital. *Eye* 2019;34(3):572-6.
10. Pei X, Yao X, Yang Y, Zhang H, Xia M, Huang R, et al. Efficacy of artificial intelligence-based screening for diabetic retinopathy in type 2 diabetes mellitus patients. *Diabetes Res Clin Pract*. 2022;184:109190.
11. Ting DS, Cheung CY, Lim G, Tan GS, Quang ND, Gan A, 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*. 2017;318(22):2211-23.
12. Dong X, Du S, Zheng W, Cai C, Liu H, Zou J. Evaluation of an Artificial Intelligence System for the Detection of Diabetic Retinopathy in Chinese Community Healthcare Centers. *Front Med (Lausanne)*. 2022;9(April):1-6.
13. Ghanchi F; Diabetic Retinopathy Guidelines Working Group. The Royal College of Ophthalmologists' clinical guidelines for diabetic retinopathy: a summary. *Eye (Lond)*. 2013;27(2):285-7.
14. Liesenfeld B, Kohner E, Piehlmeier W, Kluthe S, Aldington S, Porta M, et al. A telemedical approach to the screening of diabetic retinopathy: digital fundus photography. *Diabetes Care*. 2000;23(3):345-8.
15. Rajalakshmi R, Subashini R, Anjana RM, Mohan V. Automated diabetic retinopathy detection in smartphone-based fundus photography using artificial intelligence. *Eye (Basingstoke)*. 2018;32(6):1138-44.