

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE INFORMÁTICA
GRADUAÇÃO EM ENGENHARIA DA COMPUTAÇÃO



DESENVOLVIMENTO DE APLICATIVO PARA DETECÇÃO DE GLAUCOMA
ATRAVÉS DE RECONHECIMENTO DE IMAGEM UTILIZANDO INTELIGÊNCIA
ARTIFICIAL

Recife

2023

Universidade Federal de Pernambuco

Centro de Informática

Ayrton Barros de Lira

DESENVOLVIMENTO DE APLICATIVO PARA DETECÇÃO DE GLAUCOMA
ATRAVÉS DE RECONHECIMENTO DE IMAGEM UTILIZANDO
INTELIGÊNCIA ARTIFICIAL

Monografia apresentada ao Centro de Informática (CIN) da Universidade Federal de Pernambuco (UFPE), como requisito parcial para conclusão do Curso de Engenharia da Computação, orientada pelo professor Adriano Augusto de Moraes Sarmento.

Recife

2023

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Lira, Ayrton Barros de .

Desenvolvimento de aplicativo para detecção de glaucoma através de reconhecimento de imagem utilizando inteligência artificial / Ayrton Barros de Lira. - Recife, 2023.

29 p. : il., tab.

Orientador(a): Adriano Augusto de Moraes Sarmiento

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Pernambuco, Centro de Informática, Engenharia da Computação - Bacharelado, 2023.

1. Glaucoma. 2. VCDR. 3. Aplicação. 4. Inteligência Artificial. I. Sarmiento, Adriano Augusto de Moraes. (Orientação). II. Título.

000 CDD (22.ed.)

RESUMO

O glaucoma é uma das principais causas de cegueira irreversível, sendo uma condição médica progressiva que afeta o nervo óptico. A detecção precoce e o acompanhamento regular são, portanto, fundamentais para a prevenção da doença.. A detecção tradicional da doença muitas vezes envolve uma série de exames clínicos caros, e o uso de equipamentos especializados de difícil locomoção, dificultando o acesso para pessoas de baixa renda e de regiões remotas. Sendo assim, métodos que facilitem o diagnóstico são de extrema importância. Este trabalho procura estender o trabalho feito por SARMENTO et al. (2019) que detecta os diâmetros do disco óptico e da escavação fisiológica a partir de valores limiares fixos da intensidade da coloração dessas regiões, e a dissertação de JAILSON (2020) que propõe a utilização de uma regressão linear para a escolha dos limiares baseados na média da intensidade de coloração da imagem. Foi desenvolvida uma aplicação de fácil acesso, sendo necessário apenas um dispositivo com acesso a internet e um navegador web, assim como um dataset para o treinamento da regressão.

Palavras-chave: Glaucoma, VCDR, Aplicação

SUMÁRIO

1. INTRODUÇÃO.....	6
1.1 MOTIVAÇÃO.....	6
1.2 OBJETIVOS.....	6
1.3 ESTRUTURA.....	7
2. FUNDAMENTAÇÃO TEÓRICA.....	8
2.1 APLICAÇÕES WEB.....	8
2.1.1 REACT.....	8
2.2 DETECÇÃO DE GLAUCOMA.....	9
2.3 CONCEITOS BÁSICOS DE IMAGENS DIGITAIS.....	10
2.4 APRENDIZAGEM DE MÁQUINA.....	11
2.5 DATASETS.....	11
2.6 REGRESSÃO LINEAR E ALGORITMO BASE.....	12
3. ESTADO DA ARTE.....	14
3.1 SARMENTO.....	14
3.2 LI.....	15
4. METODOLOGIA.....	16
4.1 ABORDAGEM INICIAL.....	16
4.2 DATASET.....	18
4.3 APLICAÇÃO WEB.....	19
5. RESULTADOS.....	21
5.1 APLICAÇÃO.....	21
5.2 DATASET.....	23
5.3 REGRESSÃO LINEAR.....	23
5.4 ANÁLISE.....	24
6. CONCLUSÕES E TRABALHOS FUTUROS.....	26
7. REFERÊNCIAS.....	27

LISTA DE FIGURAS

Figura 2.1: Detecção manual do disco óptico (preto) e da escavação (azul). Imagens de SIVASWAMY et al. (2014).	9
Figura 2.2: Sistema de coordenadas (x, y) para representação dos pixels de uma imagem. Imagens de Stanford.	10
Figura 2.3: Sistema de coordenadas (x, y) e a tupla correspondente a cor para representação dos pixels de uma imagem. Imagens de Stanford.	11
Figura 3.1: (A) Imagem original. (B) Segmentação do disco óptico com base no canal R e um limiar de 230. (C) Segmentação da escavação com base no canal Y e um limiar de 200. Imagem de SARMENTO et al.	14
Figura 4.1: Diagrama de bloco do método proposto por Jailson. Imagem de JAILSON.	17
Figura 4.2: Fluxo de criação do dataset. Autoria própria.	19
Figura 4.3: Fluxo responsável pelo diagnóstico. Autoria própria.	20
Figura 5.1: Tela inicial responsável por receber a imagem da região de interesse. Autoria própria.	21
Figura 5.2: Tela para a escolha entre um diagnóstico da imagem ou a criação de entradas para o dataset. Autoria própria.	22
Figura 5.3: Tela mostrando o diagnóstico da imagem. Autoria própria.	22
Figura 5.4: Tela responsável para a seleção dos limiares, e download das entradas do dataset. Autoria própria.	23
Figura 5.5: Regressores, juntos com os dados de treino com as imagens do dataset Drishti-GS. Autoria própria.	24
Figura 5.6: Regressores, juntos com os dados de treino com as imagens do dataset RIM-ONE. Autoria própria.	24
Figura 5.7: Regressores, juntos com os dados de treino com as imagens do dataset. Autoria própria.	25

LISTA DE TABELAS

Tabela 1: Rótulos do dataset criado. Autoria própria.	18
Tabela 2: Distribuição das imagens no dataset. Autoria própria.	23
Tabela 3: Matriz de confusão para as imagens de teste. Autoria própria.	25
Tabela 4: Comparação entre os valores de r^2 e RMSE. Autoria própria.	26

1. INTRODUÇÃO

1.1 MOTIVAÇÃO

A visão é um dos sentidos mais essenciais para a experiência humana, sendo fundamental para o desenvolvimento de crianças, a cegueira podendo afetar significativamente esse processo, assim como reduzir a qualidade de vida de adultos (WHO, 2023; GUEDES, 2015). O glaucoma é uma das principais causas de cegueira irreversível, sendo uma condição médica progressiva que afeta o nervo óptico. A detecção precoce e o acompanhamento regular são, portanto, fundamentais para a prevenção da doença.

A detecção tradicional da doença muitas vezes envolve uma série de exames clínicos caros, que podem ser financeiramente inacessíveis para parte da população. Isso resulta em um cenário preocupante, onde muitos pacientes de baixa renda não conseguem acessar o diagnóstico precoce e, como resultado, enfrentam complicações e custos médicos ainda maiores no futuro.

Portanto é de interesse da sociedade a prevenção e o diagnóstico precoce do glaucoma, porém os equipamentos necessários para o diagnóstico são caros e de difícil locomoção, dificultando o acesso a pacientes em regiões remotas.

A proposta do trabalho é disponibilizar uma ferramenta que facilite o diagnóstico do glaucoma, expandindo o método proposto no trabalho de graduação do aluno da Universidade Federal de Pernambuco Jailson José Gomes da Silva Junior (JAILSON, 2020).

1.2 OBJETIVOS

O trabalho tem como objetivo analisar a solução proposta (JAILSON, 2020), procurar melhorar o resultado do mesmo criando um dataset com rótulos para as médias de coloração das imagens.

O trabalho também busca criar uma aplicação que utiliza o resultado da regressão linear para classificar imagens do fundo da retina, assim como a opção de gerar manualmente uma entrada para o dataset.

Após a implementação, os resultados foram comparados com o objetivo de observar se houve uma melhora de acurácia, vale ressaltar que não foi possível obter o dataset utilizado (JAILSON, 2020) impossibilitando reproduzir alguns resultados.

Com isto o trabalho propõe disponibilizar uma ferramenta de fácil acesso, e baixo custo operacional para facilitar o diagnóstico inicial de glaucoma, assim como ferramentas para que facilitem a expansão do mesmo na forma de um dataset e uma aplicação para rotulações.

1.3 ESTRUTURA

Este trabalho possui 6 capítulos: O capítulo 2 introduz a fundamentação teórica necessária para entender os principais tópicos do trabalho. O capítulo 3 apresenta o estado da arte, descrevendo o que há de mais atual relacionado ao trabalho. O capítulo 4 mostra o sistema proposto, as dificuldades encontradas durante a implementação do mesmo e as soluções que foram introduzidas. No capítulo 5 será demonstrado o sistema implementado assim como um comparativo dos resultados. Já o capítulo 6 apresenta a conclusão e os possíveis trabalhos futuros.

2. FUNDAMENTAÇÃO TEÓRICA

Este capítulo vai introduzir a fundamentação teórica necessária para entender os principais tópicos do trabalho. Nele serão explicados conceitos básicos sobre aplicações, glaucoma e datasets, assim como algoritmo base do projeto e regressão linear.

Inicialmente, serão abordadas aplicações Web. Em seguida, será discutida a detecção do glaucoma, e conceitos básicos sobre imagens digitais. Posteriormente, regressão linear e o algoritmo base do projeto. E por último o que são datasets.

2.1 APLICAÇÕES WEB

Aplicações Web, são programas que são acessados por meio de um navegador da web. Elas podem funcionar em qualquer dispositivo com um navegador compatível, como computadores, smartphones ou tablets, sem a necessidade de instalação, podendo assim serem usadas para uma ampla variedade de finalidades.

Para este projeto foi escolhido o framework React para a implementação da aplicação.

2.1.1 REACT

React é uma biblioteca JavaScript de código aberto desenvolvida e mantida pela Meta. Ela é amplamente utilizada para a criação de interfaces de usuário (UI) dinâmicas e interativas em aplicações web. O React se destaca por sua abordagem baseada em componentes, que permite dividir a interface do usuário em componentes reutilizáveis e autônomos (META, 2021).

Os componentes são blocos isolados de código que encapsulam lógica e funcionalidade específicas. Isso facilita a criação, manutenção e reutilização de partes individuais da interface, tornando o desenvolvimento mais organizado e eficiente.

Além disso, o React é suportado por uma comunidade ativa de desenvolvedores e empresas, o que significa que há uma abundância de recursos, documentação e exemplos disponíveis para ajudar os desenvolvedores a aprender e aprimorar suas habilidades no uso dessa biblioteca.

2.2 DETECÇÃO DE GLAUCOMA

Existem diversas abordagens para o diagnóstico do glaucoma, neste trabalho o foco será na análise de imagens de fundo de olho. Na imagem é possível observar o disco óptico assim como uma região conhecida como escavação fisiológica localizada na área central do disco óptico.



Figura 2.1: Detecção manual do disco óptico (preto) e da escavação (azul).

Imagens de SIVASWAMY et al. (2014).

Há fortes indícios que uma relação vertical dos diâmetros escavação/disco (VCDR) maior seja o resultado de glaucoma. Porém os diagnósticos que usam o VCDR são utilizados primariamente para verificar o

grau de risco do paciente, e conseqüentemente serem dirigidos para realizar outros exames.

2.3 CONCEITOS BÁSICOS DE IMAGENS DIGITAIS

Uma imagem digital pode ser representada por um sistema de coordenadas x e y , onde uma coordenada (x, y) representa um pixel. As cores dos pixels podem ser definidas de diversas maneiras, neste trabalho são usadas a decomposição de cores nos canais RGB e YCbCr.

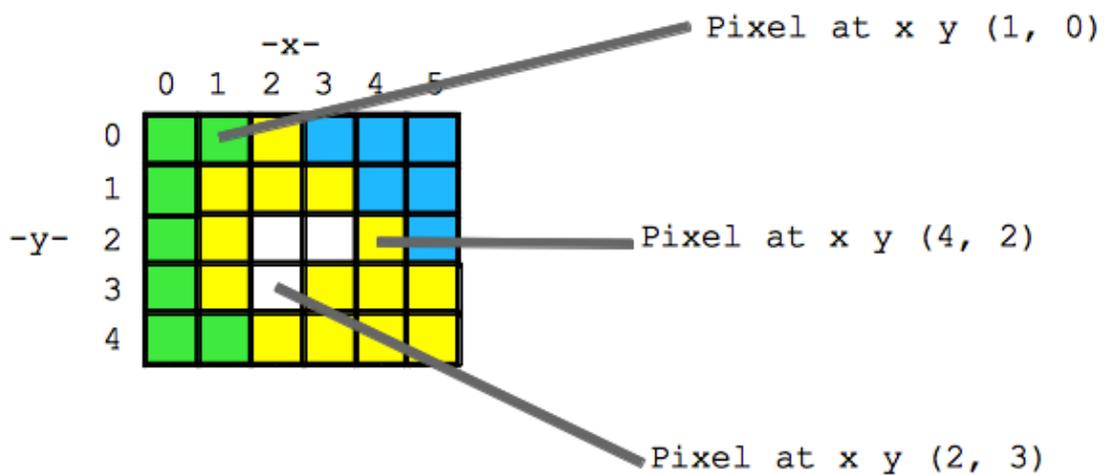


Figura 2.2: Sistema de coordenadas (x, y) para representação dos pixels de uma imagem.
Imagens de Stanford.

Nos canais RGB cada pixel possui uma tupla (R, G, B) onde os valores da tupla representam a intensidade do seu respectivo canal (Vermelho, Verde, Azul) entre uma faixa de 0 a 255.

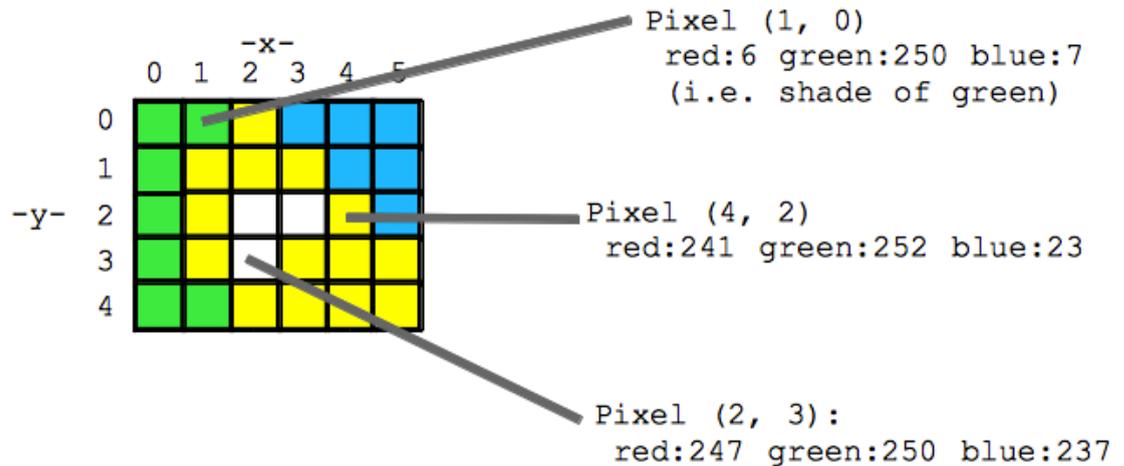


Figura 2.3: Sistema de coordenadas (x, y) e a tupla correspondente a cor para representação dos pixels de uma imagem. Imagens de Stanford.

Já nos canais YCbCr teremos a tupla (Y, Cb, Cr) onde o canal Y é intensidade da luz da imagem, e os canais Cb e Cr os componentes croma de diferença azul e vermelha respectivamente.

2.4 APRENDIZAGEM DE MÁQUINA

Machine learning é uma área da inteligência artificial (IA) e da ciência da computação que se concentra no uso de dados e algoritmos para imitar a maneira como os humanos aprendem, melhorando gradualmente sua precisão (IBM, 2023).

O aprendizado supervisionado é uma abordagem em que os dados utilizados para treinamento são rotulados com a(s) entrada(s) e a saída. Já na aprendizagem não supervisionada os dados não possuem rótulos e os métodos procuram por padrões para associá-los.

2.5 DATASETS

Um dataset é um conjunto organizado de dados, geralmente apresentado em forma de tabela que é utilizado para análise, pesquisa, treinamento de modelos de inteligência artificial, tomada de decisões, entre outras finalidades (SNIJDERS et al, 2012). Onde na tabela cada linha

representa um dado e cada coluna uma variável descrevendo tal dado, no caso de aprendizado supervisionado, os datasets podem incluir rótulos ou alvos que representam a variável que se deseja prever.

Neste trabalho o dataset será composto de imagens obtidas dos bancos Drishti-GS e Rim-One, a médias do canal R e do canal Y obtidas utilizando a ferramenta desenvolvida e o rótulo contendo o VCDR das mesmas.

2.6 REGRESSÃO LINEAR E ALGORITMO BASE

A regressão linear é uma técnica estatística fundamental usada para modelar a relação entre uma variável dependente (ou resposta) e variáveis independentes (ou preditoras) em um contexto de análise de dados.

A ideia central por trás da regressão linear é encontrar a melhor linha reta (ou hiperplano, em casos de múltiplas variáveis independentes) que descreve a relação entre as variáveis de forma que minimize a soma dos erros quadrados, ou seja, que minimize a distância entre os valores observados da variável dependente e os valores previstos pela linha reta.

A equação geral de uma regressão linear simples (com apenas uma variável independente) pode ser expressa da seguinte maneira:

$$y = \alpha + \beta x + \varepsilon$$

Onde y é a variável dependente que estamos tentando prever, x é a variável independente (preditora) que usamos para fazer a previsão. α é a interseção da reta com o eixo y , β é o coeficiente de inclinação da reta, e ε é o erro aleatório, que representa a diferença entre os valores observados e os valores previstos.

Para avaliar o desempenho modelo se utilizam de algumas métricas como o coeficiente de determinação (r^2) e a raiz quadrado do erro médio (RMSE). O coeficiente de determinação varia de 0 a 1, onde 1 indica que o modelo é capaz de explicar a maior parte da variação na variável dependente e 0 indica que o modelo não consegue explicar bem a variação na variável

dependente. Valores acima de 0,7 já indicam que há uma correlação significativa.

Já o RMSE mede a raiz quadrada da média dos quadrados das diferenças entre os valores observados e os valores previstos pelo modelo, podendo assim mostrar o quão distante as previsões do modelo estão dos valores reais.

3. ESTADO DA ARTE

Neste capítulo veremos trabalhos relacionados e suas contribuições, focando em estudos que buscam facilitar o acesso ao diagnóstico de glaucoma.

3.1 SARMENTO

Neste trabalho SARMENTO (2019) desenvolveu um dispositivo eletrônico móvel para calcular o valor do VCDR a partir de imagens do disco óptico obtidas por um retinógrafo. Para realização do cálculo do VCDR foi-se necessário identificar o disco óptico e a escavação para a medição de seus diâmetros verticais, para isso o dispositivo analisa o canal R como um valor de limiar de 230 e o canal Y com um valor de limiar de 200, onde os pixels com valores maiores ou iguais ao limiar do canal R pertence ao disco óptico e os pixels com valores iguais ou maiores ao canal Y pertencem a escavação.

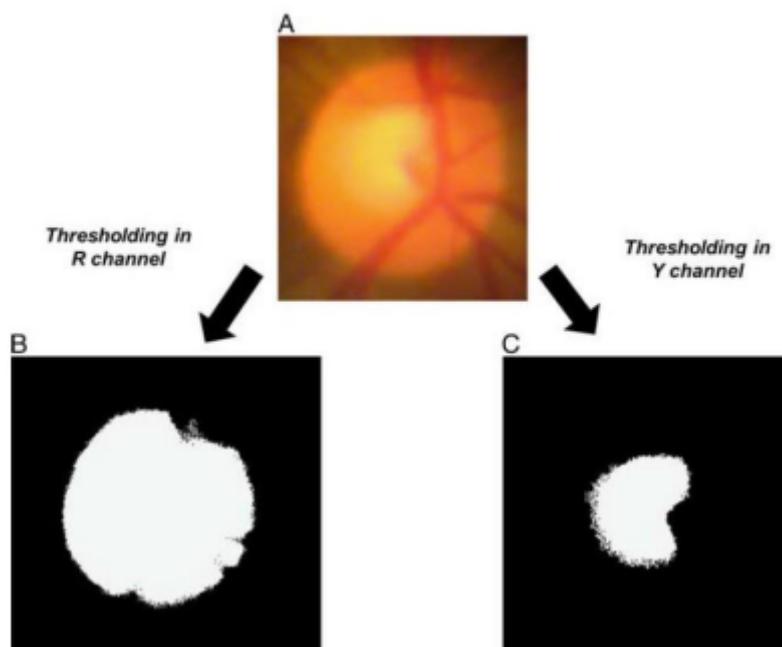


Figura 3.1: (A) Imagem original. (B) Segmentação do disco óptico com base no canal R e um limiar de 230. (C) Segmentação da escavação com base no canal Y e um limiar de 200.

Imagem de SARMENTO et al.

Diferente de SARMENTO que utilizava limiares fixos, JAILSON (2020) percebeu uma relação entre a intensidade média dos pixels e os valores dos limiares tanto para o canal R quanto para Y, e propôs assim a utilização da regressão linear para determinar estes valores.

3.2 LI

LI (2020) desenvolveu uma aplicação para telefones celulares para o diagnóstico de pacientes baseado em exames de campo de visão, utilizando aprendizagem profunda para classificar o exame.

O modelo obteve uma ótima acurácia porém é extremamente custoso levando horas para o treinamento assim como a necessidade de uma grande quantidade de dados para o treinamento.

O aplicativo é apenas responsável por enviar as imagens para um servidor, que faz a devida classificação.

4. METODOLOGIA

Neste capítulo será descrito o sistema desenvolvido sendo ele uma extensão dos trabalhos SARMENTO (2019) e JAILSON (2020), foi implementada uma aplicação web para facilitar o uso do algoritmo de detecção automática assim como a criação de um dataset com os devidos rótulos para o treinamento.

4.1 ABORDAGEM INICIAL

Para o treinamento da regressão linear é preciso que as imagens venham acompanhadas dos seus respectivos limiares nos para o canal R e o canal Y, porém as imagens de fundo de olho disponíveis só possuem o valor do VCDR. Em JAILSON (2020) os limiares foram preenchidos empiricamente, sendo escolhidos com base no valores de VCDR disponíveis, porém não foi possível obter este dataset sendo necessário a criação de um novo.

O método proposto por Jailson, figura 4.1, recebe imagens da região de interesse, se faz um redirecionamento para facilitar operações futuras, são retiradas as médias dos canais R e Y e aplicadas nos respectivos regressores que irão retornar os valores dos limiares. Com estes valores é possível fazer as segmentações do disco óptico e da escavação, estimando o VCDR e classificando a imagem.

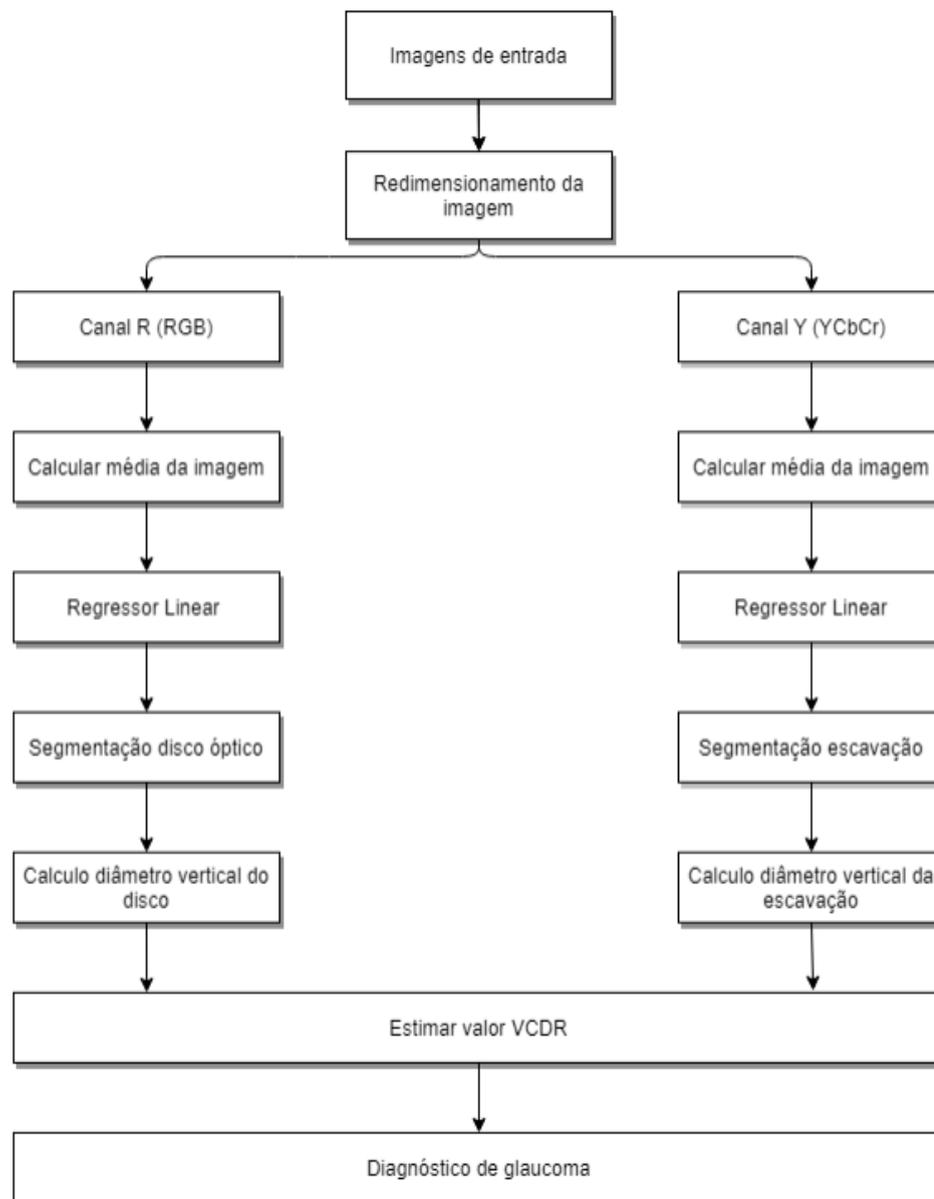


Figura 4.1: Diagrama de bloco do método proposto por Jailson. Imagem de JAILSON.

Este trabalho propõe a implementação de uma aplicação web que permita utilizar o resultado da regressão para classificar uma imagem, e que também facilite o processo de criação de entradas para o dataset.

4.2 DATASET

Este trabalho irá usar imagens dos repositórios Drishti-GS e RIM-ONE para a criação de dataset. Ambos os datasets possuem imagens classificadas entre olhos normais e olhos com glaucoma, assim como o valor de VCDR. O dataset criado possuirá os rótulos mostrados na tabela 1, também será focado em manter um balanceamento adequado entre imagens de olhos saudáveis e olhos com glaucoma.

Tabela 1: Rótulos do dataset criado. Autoria própria.

Limiar do canal R
Média do canal R
Limiar do canal Y
Média do canal Y
VCDR

4.3 APLICAÇÃO WEB

A aplicação web possuirá dois fluxos, o primeiro será responsável pela criação das entradas do dataset, é feito um upload da imagem para aplicação onde é possível ajustar os limiares dos canais R e Y para os valores adequados, resultando em entrada.

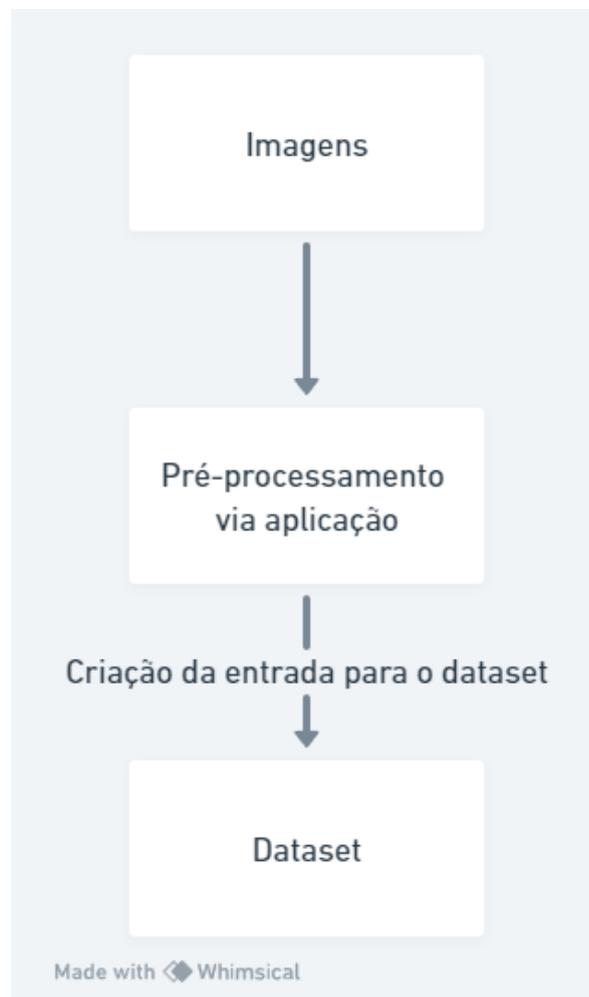


Figura 4.2: Fluxo de criação do dataset. As imagens são inseridas na aplicação onde é feita a escolha dos limiares com auxílio visual. Autoria própria.

Já o segundo fluxo é responsável por classificar uma imagem de fundo de olho enviada pelo usuário, utilizando os parâmetros obtidos pelo treinamento das regressões

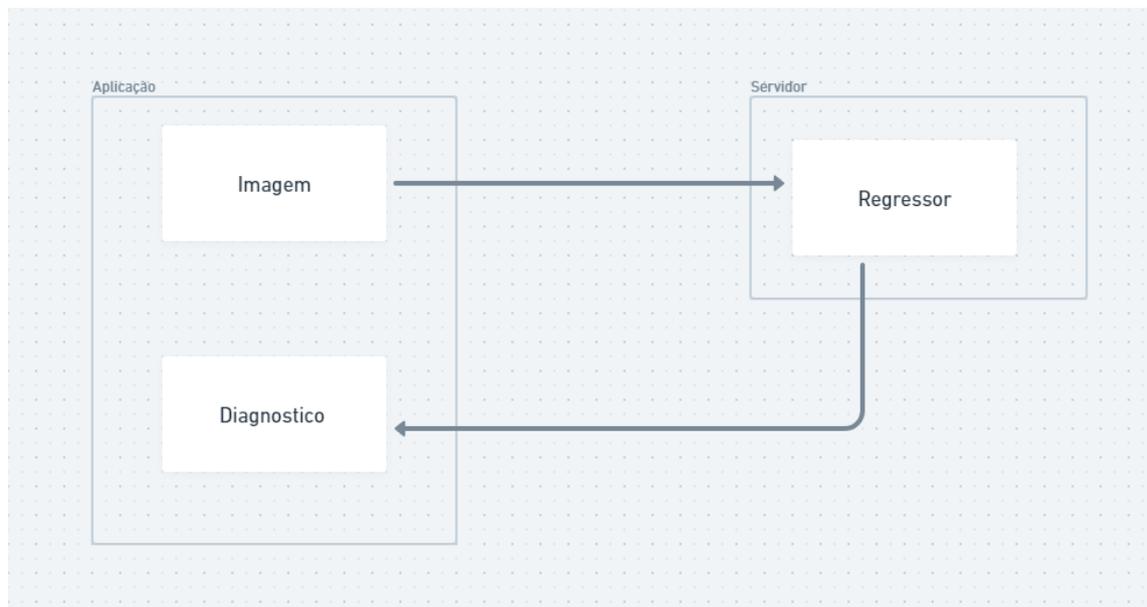


Figura 4.3: Fluxo responsável pelo diagnóstico. As imagens são enviadas para o servidor, onde é aplicado o regressor feito por JAILSON (2020) e é retornado o diagnóstico. Autoria própria.

5. RESULTADOS

Neste capítulo inicialmente será apresentada a aplicação implementada e suas funções, logo após será descrito o dataset gerado a partir da aplicação, e por último será feito um comparativo ao dataset utilizado por JAILSON(2020)

5.1 APLICAÇÃO

As figuras 5.1, 5.2, 5.3 mostram o fluxo da aplicação assim como suas funcionalidades.



Figura 5.1: Tela inicial responsável por receber a imagem da região de interesse. Autoria própria.



Figura 5.2: Tela para a escolha entre um diagnóstico da imagem ou a criação de entradas para o dataset. Autoria própria.



Figura 5.3: Tela mostrando o diagnóstico da imagem. Autoria própria.

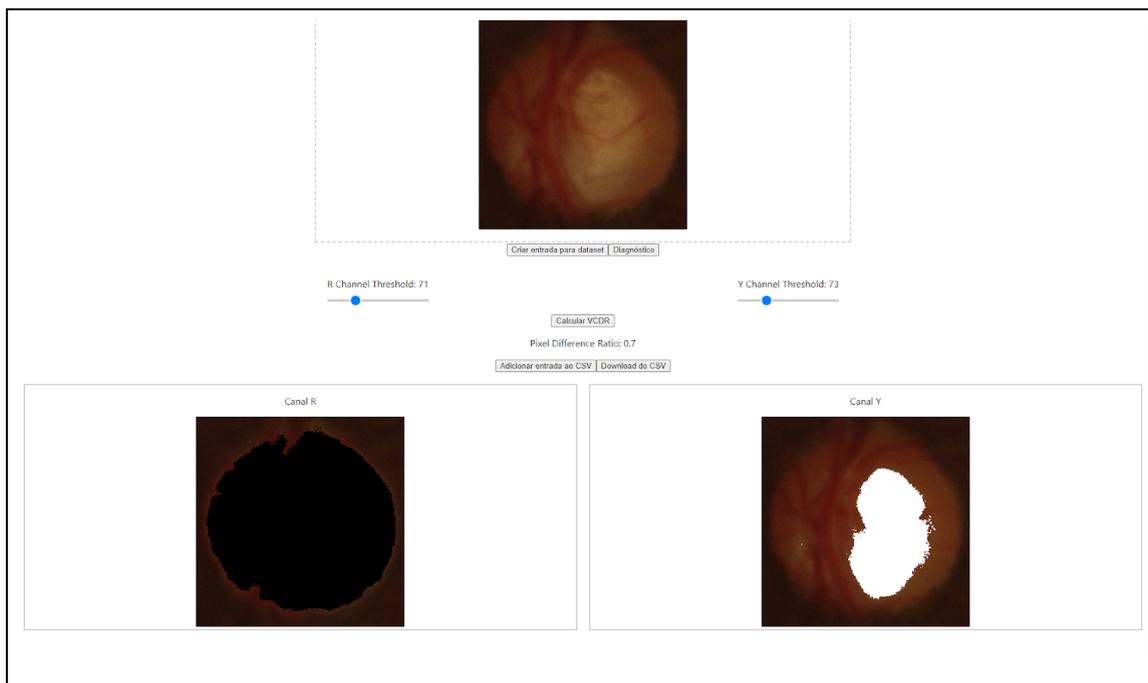


Figura 5.4: Tela responsável para a seleção dos limiares, e download das entradas do dataset.
 Autoria própria.

5.2 DATASET

O dataset foi criado com imagens de fundo de olho obtidas a partir dos bancos de imagens Drishti e RIM-ONE, ao total foram-se utilizadas 96 imagens para o treino e 40 para o teste, com um total de 136 imagens com a seguinte distribuição.

Tabela 2: Distribuição das imagens no dataset. Autoria própria.

Repositório	Treino		Teste	
	Normal	Glaucoma	Normal	Glaucoma
Drishiti-GS	18	32	10	10
RIM-ONE	25	21	10	10

5.3 REGRESSÃO LINEAR

O objetivo foi observar o desempenho do dataset comparado ao utilizado no trabalho base, para o conjunto de imagens obtidas do banco Drishti-GS foi obtido um coeficiente de determinação r^2 de 0,89 e um RMSE de 10,6 para o canal R, e um coeficiente de determinação r^2 de 0,87 e um RMSE de 8,7 para o canal Y.

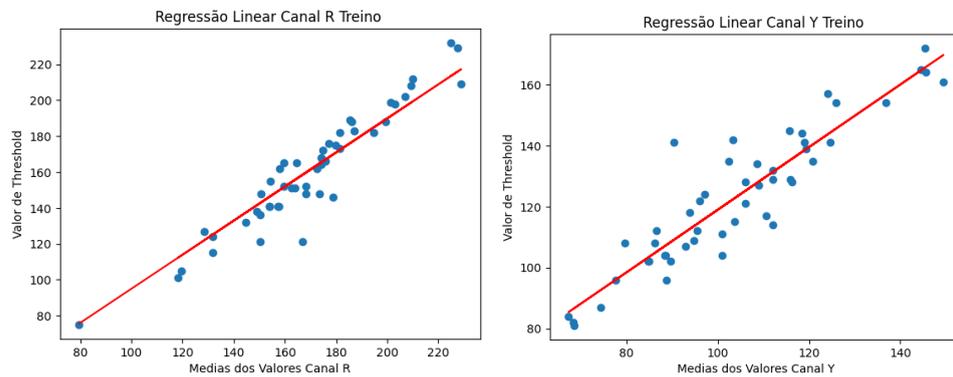


Figura 5.5: Regressores, juntos com os dados de treino com as imagens do dataset Drishti-GS. Autoria própria.

Já para as imagens obtidas do RIM-ONE temos um coeficiente de determinação r^2 de 0,95 e um RMSE de 8,3 para o canal R, e um coeficiente de determinação r^2 de 0,88 e um RMSE de 11,9 para o canal Y.

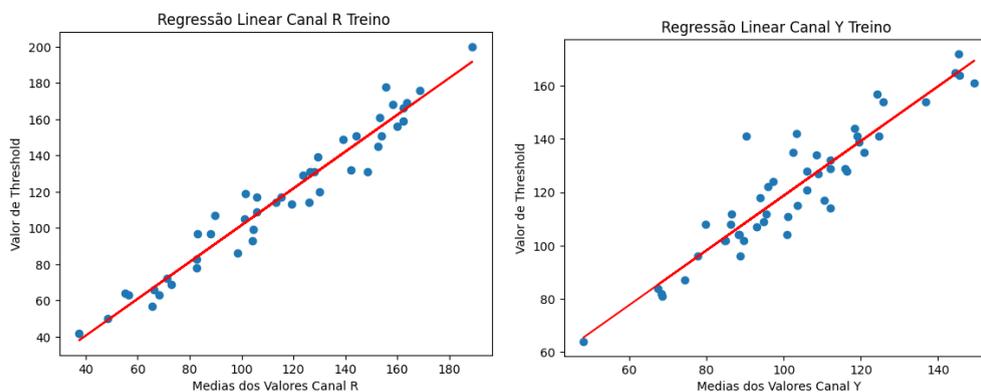


Figura 5.6: Regressores, juntos com os dados de treino com as imagens do dataset RIM-ONE. Autoria própria.

Por último os dois bancos foram unidos, com isso obtivemos um coeficiente de determinação r^2 de 0,93 e um RMSE de 10,6 para o canal R, e um coeficiente de determinação r^2 de 0,76 e um RMSE de 15,2 para o canal Y.

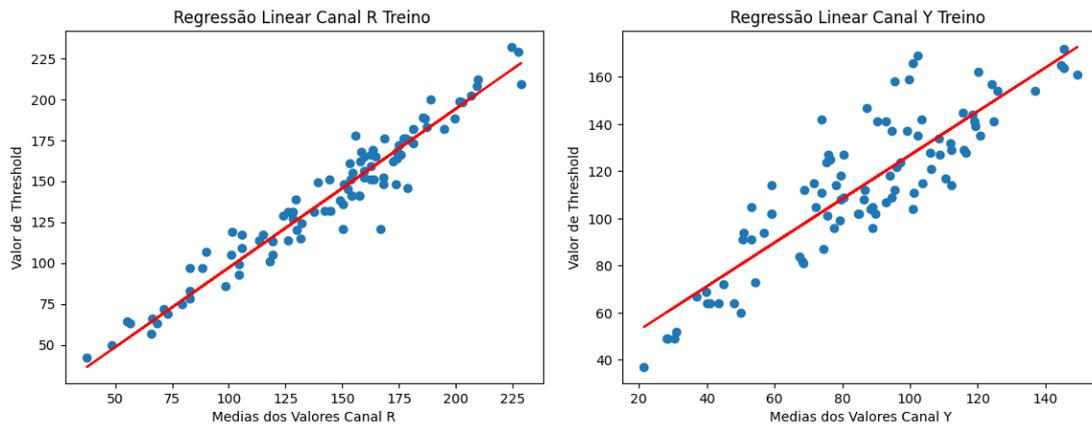
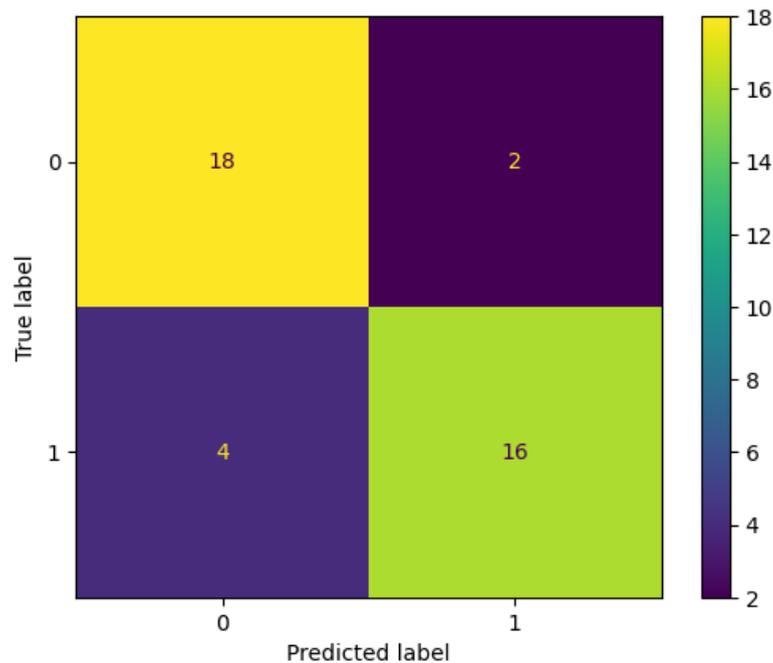


Figura 5.7: Regressores, juntos com os dados de treino com as imagens do dataset. Autoria própria.

Já para as imagens de teste o resultado obtido foi um F1 score de 84% com os resultados obtidos segundo a tabela 3.

Tabela 3: Matriz de confusão para as imagens de teste. Autoria própria.



5.4 ANÁLISE

A ferramenta proposta consegue apresentar um diagnóstico em menos de 1s necessitando apenas de internet e um dispositivo com acesso a um navegador web, assim como facilita consideravelmente a rotulação das imagens de fundo e olho para o treinamento do modelo.

O dataset criado também apresentou bons resultados após o treinamento quando comparados ao obtidos por JAILSON.

Tabela 4: Comparação entre os valores de r^2 e RMSE. Autoria própria.

Repositório	Canal R		Canal Y	
	r^2	RMSE	r^2	RMSE
Drishti-GS + RIM-ONE	0,93	10,6	0,76	15,2
JAILSON	0,7	15,6	0,5	22,56

6. CONCLUSÕES E TRABALHOS FUTUROS

O objetivo deste trabalho foi proporcionar uma ferramenta de fácil acesso que ofereça um diagnóstico primário de glaucoma utilizando o método proposto por Jailson. Assim como a criação de um dataset e a uma ferramenta para a criação do mesmo.

A ferramenta pode ser acessada por qualquer dispositivo com acesso a um navegador web, necessitando de baixo custo operacional no usuário final já que a regressão linear é pré-processada no servidor. A ferramenta também facilita consideravelmente o pré-processamento e a rotulação das imagens para criação de um dataset.

Em trabalhos futuros podemos acoplar mais métodos de classificação proporcionando uma maior gama de resultados e conseqüentemente um melhor diagnóstico, assim como adicionar mais opções a seção de edição de imagem possibilitando a criação de diferentes rótulos para as imagens para serem usados para o treinamento com outros métodos.

7. REFERÊNCIAS

- EYETECHCARE , 17 set. 2020. Disponível em:
<https://eyetechcare.com/en/glaucoma/understanding-glaucoma>. Acesso em: 10 set. 2023.
- FREITAS, Sirley Maria de et al. Economic evaluation of primary open-angle glaucoma. *Rev Bras Oftalmol.*, v. 78, n. 4, p. 233-238, Aug. 2019.
- GOMES, Jailson. Definição De Parâmetros Limiares Em Imagens Da Retina Para Detecção De Glaucoma Utilizando Técnicas De Inteligência Artificial, abr. 2021. Disponível em: https://www.cin.ufpe.br/~tg/2020-1/TG_EC/tg_jgsj.pdf. Acesso em: 10 set. 2023.
- GUEDES, Ricardo Augusto Paletta. Qualidade de vida e glaucoma. *Rev Bras Oftalmol.*, v. 74, n. 3, p. 131-132, jun. 2015.
- IBM. O que é machine learning?, jun. 2023. Disponível em:
<https://www.ibm.com/br-pt/topics/machine-learning>. Acesso em: 10 set. 2023.
- LI, Fei et al. Development and clinical deployment of a smartphone-based visual field deep learning system for glaucoma detection. *NPJ digital medicine*, v. 3, n. 1, p. 1-8, 2020.
- LI, Liu et al. Attention based glaucoma detection: A large-scale database and CNN Model. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. p. 10571-10580. 2019.
- META. React, jun. 2021. Disponível em: <https://opensource.fb.com/projects/react/>. Acesso em: 10 set. 2023.
- PEDROSO, L. et al.. Custo real do tratamento do glaucoma para o paciente. *Arquivos Brasileiros de Oftalmologia*, v. 62, n. 6, p. 677–682, dez. 1999.
- PENA-BETANCOR, Cristina et al. Estimation of the Relative Amount of Hemoglobin in the Cup and Neuroretinal Rim Using Stereoscopic Color Fundus Images. *Invest. Ophthalmol. Vis. Sci.* 2015;56(3):1562-1568.
- SARMENTO, Andrea GL et al. Determining Optic Nerve Cupping Using Optical Coherence Tomography (OCT) Versus a New Electronic Mobile Device. *Journal of glaucoma*, v. 28, n. 5, p. 398-403, 2019.
- SIVASWAMY, Jayanthi et al. A comprehensive retinal image dataset for the assessment of glaucoma from the optic nerve head analysis. *JSM Biomedical Imaging Data Papers*, v. 2, n. 1, p. 1004, 2015.

SIVASWAMY, Jayanthi et al. Drishti-gs: Retinal image dataset for optic nerve head (onh) segmentation. In: 2014 IEEE 11th international symposium on biomedical imaging (ISBI). IEEE, 2014. p. 53-56.

SNIJDERS, Chris; MATZAT, Uwe; REIPS, Ulf-Dietrich. "Big Data" : Big Gaps of Knowledge in the Field of Internet Science. International Journal of Internet Science. 7. 1-5. jan, 2012.

STANFORD. Introduction to Digital Images, apr. 2013. Disponível em: <https://web.stanford.edu/class/cs101/image-1-introduction.html>. Acesso em: 10 set. 2023.

WHO. Blindness and vision impairment, ago. 2020. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/blindness-and-visual-impairment>. Acesso em: 10 set. 2023.