

GlaucoAware: Desenvolvimento de uma ferramenta de classificação de glaucoma em imagens do fundo ocular utilizando CNNs

Jeanderson Gomes de Sousa
Programa de Pós-Graduação em
Engenharia Eletrica
Universidade Federal do Piauí,
Brasil
jeandsgomes10@ufpi.edu.br

Luis Eduardo Silva Brio
Departamento de Sistemas de
Informação,
Universidade Federal do Piauí,
Brasil
duardos36@gmail.com

Alcilene Dalfília
Departamento de Sistemas de
Informação,
Universidade Federal do Piauí,
Brasil
alcilene@ufpi.edu.br

Romuere Rodrigues Veloso E
Silva
Programa de Pós-Graduação em
Engenharia Eletrica,
Doutorado em Ciência da
Computação,
Departamento de Sistemas de
Informação,
Universidade Federal do Piauí,
Brasil
romuere@ufpi.edu.br

Antonio Oseas de Carvalho
Filho
Programa de Pós-Graduação em
Engenharia Eletrica,
Doutorado em Ciência da
Computação,
Departamento de Sistemas de
Informação,
Universidade Federal do Piauí,
Brasil
antoniooseas@ufpi.edu.br

Flávio Henrique Duarte De
Araújo
Programa de Pós-Graduação em
Engenharia Eletrica,
Doutorado em Ciência da
Computação,
Departamento de Sistemas de
Informação,
Universidade Federal do Piauí,
Brasil
flavio86@ufpi.edu.br

RESUMO

O glaucoma é uma condição oftalmológica progressiva e degenerativa, caracterizada pelo aumento da pressão intraocular, que danifica o nervo óptico resultando em perda irreversível da visão periférica, podendo levar à cegueira total. Essa doença é uma das principais causas de cegueira no mundo, afetando milhões de pessoas. A detecção do glaucoma pelo oftalmologista analisa detalhadamente o fundo ocular, um processo geralmente demorado e exaustivo. Este trabalho aborda o desenvolvimento de um sistema automatizado com interface gráfica de usuário gratuita para diagnóstico de glaucoma, visando otimizar a triagem em larga escala. Para treinar e avaliar os modelos de classificação, foi utilizada a base de dados SMDG-19, composta por 12.449 imagens. O modelo *DenseNet201* se destacou, alcançando os melhores resultados, com acurácia, precisão e recall de 86%, e um AUC de até 0,94.

Palavras-chave

Deep Learning; Sistemas CAD; Diagnóstico automatizado; Interface gráfica de usuário.

ABSTRACT

Glaucoma is a progressive and degenerative ophthalmological condition characterized by increased intraocular pressure, which damages the optic nerve and results in irreversible loss of peripheral vision, which can lead to total blindness. This disease is one of the main causes of blindness in the world, affecting millions of people. Glaucoma detection by the ophthalmologist requires a detailed analysis of the fundus of the eye, a process that is usually time-consuming and exhaustive. This work addresses the development of an automated system with a free graphical user interface for glaucoma diagnosis, aiming to optimize large-scale screening. To train and evaluate the classification models, the SMDG-19

database, composed of 12,449 images, was used. The *DenseNet201* model stood out, achieving the best results, with accuracy, precision, and recall of 86%, and an AUC of up to 0,94.

Keywords

Deep Learning; CAD Systems; Automated Diagnostics; Graphical User Interface.

1. INTRODUÇÃO

O glaucoma é uma doença progressiva e degenerativa que atinge diretamente o nervo óptico dos olhos. Neste sentido, se não for tratada adequadamente, pode resultar em danos visuais graves e até mesmo a cegueira completa. A principal causa do glaucoma é o aumento da pressão intraocular, na qual resulta na degeneração do nervo óptico [5]. Estima-se que entre 76,0 e 79,6 milhões de pessoas foram afetadas pelo glaucoma em 2020, e esse número pode crescer para mais de 111,8 milhões até 2040 [9].

No entanto, quando identificado precocemente, o glaucoma pode ser controlado e até prevêido. Diante disso, os oftalmologistas utilizam imagens de fundo ocular para diagnosticar precocemente a doença e monitorar sua progressão ao longo do tempo, evitando assim danos que podem ser irreversíveis à saúde ocular do paciente [8]. Esse acompanhamento contínuo permite a intervenção dos oftalmologistas para minimizar as chances de danos mais sérios a saúde ocular dos indivíduos.

Nesse contexto, é extremamente importante compreender a estrutura do disco óptico, que é composto por duas regiões principais: a borda neuro-retiniana, que representa a área periférica, e a copa óptica, situada na região central [14]. Conforme a doença se prolifera, ocorrem mudanças na estrutura do disco óptico. Identificar e monitorar essas alterações é fundamental para o

acompanhamento da doença. Entretanto, a detecção automática dessas estruturas enfrenta desafios devido à variabilidade entre os pacientes.

As técnicas de Inteligência Artificial (IA) têm avançado na área da medicina. Nesse contexto, algoritmos de IA e redes neurais convolucionais conseguem detectar detalhes considerados importantes nas imagens que podem passar despercebidos pelos oftalmologistas. Além disso, essas tecnologias permitem a análise de grandes volumes de dados, facilitando a detecção precoce de doenças oculares e contribuindo para um tratamento e uma melhor qualidade de vida para os pacientes.

Com base no exposto, este trabalho apresenta o desenvolvimento de um sistema com interface gráfica intuitiva e de fácil uso, capaz de realizar a detecção do glaucoma a partir de imagens retinianas, utilizando técnicas de aprendizado profundo e Inteligência Artificial para extrair características relevantes das imagens. Foram avaliadas as arquiteturas *ResNet152V2*, *DenseNet201*, *MobileNet* e *EfficientNetV2L*, aplicadas à base de dados SMDG-19, que contém 12.449 imagens. O estudo inclui uma revisão de trabalhos relacionados, a descrição da metodologia empregada, a análise comparativa do desempenho das arquiteturas testadas e, por fim, a apresentação das conclusões e perspectivas para pesquisas futuras.

2. TRABALHOS RELACIONADOS

Na presente seção, são apresentados os trabalhos que têm alguma relação com aplicações de classificação de glaucoma em imagens de fundo ocular.

No método apresentado no trabalho [4], foi proposta a arquitetura *AlterNet-K*, que combina *ResNets* e autoatenção multicabeça (MSA) para melhorar a classificação de imagens do fundo ocular no diagnóstico de glaucoma. Treinado no conjunto de dados *Rotterdam EyePACS AIROGS*, com 113.893 imagens de 60.357 indivíduos, o modelo obteve precisão de 91,6%, AUROC de 96,8% e *F1-score* de 91,5%, superando modelos como *ViT*, *DeiT-S*, *Swin*, *ResNet*, *EfficientNet*, *MobileNet* e *VGG*. A combinação de Redes Neurais Convolucionais (CNNs) menores com MSA demonstrou alta eficácia, podendo ser adaptada para outras tarefas médicas.

O estudo de [2], propõe a arquitetura *CDAM-Net*, uma CNN multiescala leve para detecção de glaucoma. Avaliado no conjunto de dados RFI com 1426 imagens (837 glaucoma e 589 normais), o modelo atingiu 99,30% de acurácia, superando modelos tradicionais. O CDAM-Net demonstrou eficácia mesmo com menos dados de treinamento e em testes com múltiplos conjuntos de dados, destacando-se como ferramenta promissora para apoiar diagnósticos oftalmológicos.

No trabalho [7] foi empregado o banco de dados PAPILA, composto por 488 imagens, que reúne imagens do fundo ocular e parâmetros clínicos para aprimorar a detecção do glaucoma. Para melhorar a qualidade das imagens, é aplicada a técnica de redução de ruído ODnCNN. Em seguida, são extraídos recursos estatísticos que, junto aos parâmetros clínicos. Na etapa de seleção e otimização de recursos, são empregadas a regressão linear múltipla otimizada bayesiana e a regressão de vetor de suporte otimizado por busca em grade. A classificação final é conduzida por uma SVM. O método ODnCNN-ML, que integra aprendizado de máquina e parâmetros clínicos, atinge 98% de precisão na classificação entre as classes Saudável, Glaucoma e Suspeito.

Tabela 1. Resumo dos trabalhos encontrados sobre classificação de glaucoma.

Referência	Metodo	Base de Dados	Resultados
[4]	Arquitetura <i>AlterNet-K</i> combinando <i>ResNets</i> e autoatenção multicabeça (MSA) para classificação de imagens do fundo ocular no diagnóstico de glaucoma.	<i>Rotterdam EyePACS AIROGS</i> com 113.893 imagens de 60.357 indivíduos.	Precisão de 91,6%, AUROC de 96,8%, <i>F1-score</i> de 91,5%, superando modelos como <i>ViT</i> , <i>DeiT-S</i> , <i>Swin</i> , <i>ResNet</i> , <i>EfficientNet</i> , <i>MobileNet</i> e <i>VGG</i> .
[2]	Arquitetura <i>CDAM-Net</i> , uma CNN multiescala leve para detecção de glaucoma.	Conjunto de dados RFI, com 1426 imagens (837 de glaucoma e 589 normais).	Acurácia de 99,30%, superando modelos tradicionais e demonstrando eficácia com dados limitados de treinamento.
[7]	Técnica <i>ODnCNN-ML</i> , que integra aprendizado de máquina e parâmetros clínicos. A redução de ruído <i>ODnCNN</i> é aplicada e seguida de otimização usando regressão linear múltipla e SVM.	<i>PAPILA</i> com 488 imagens, incluindo parâmetros clínicos para detecção aprimorada de glaucoma.	Precisão de 98% na classificação entre as classes Saudável, Glaucoma e Suspeito.
[11]	Arquitetura <i>DeepEyeNet</i> que utiliza <i>ConvNeXtTiny</i> otimizado por AGBO, com segmentação do disco óptico por <i>U-Net</i> e extração de características.	<i>EyePACS-AIROGS-light-V2</i> , composto por 4000 imagens.	Precisão de 95,84%, superando modelos como <i>VGG16</i> , <i>ResNet50</i> e <i>EfficientNetB0</i> .
Trabalho Atual	Sistema automatizado com interface gráfica baseado em redes neurais convolucionais (<i>DenseNet201</i>) para detecção de glaucoma em imagens do fundo ocular.	Base SMDG-19, com 12.449 imagens de retina.	O <i>DenseNet201</i> alcançou 86% de acurácia e AUC de 0,94. O GlaucoAware destaca-se por integrar múltiplas CNNs em uma ferramenta gráfica gratuita que unifica interface, banco de dados e API, utilizando a base SMDG-19.

O artigo [11], apresenta a arquitetura *DeepEyeNet*, que realiza detecção automatizada de glaucoma utilizando imagens de fundo de olho, que integra a padronização de imagens por limiarização dinâmica, segmentação precisa do disco óptico pelo modelo *U-Net*, e extração de características, combinadas em um classificador baseado na arquitetura *ConvNeXtTiny* otimizado pelo algoritmo *Adaptive Genetic Bayesian Optimization* (AGBO). O dataset empregado foi o *EyePACS-AIROGS-light-V2*, composto por 4000 imagens. Como resultado, o *DeepEyeNet* obteve uma precisão de

95,84%, superando modelos como *VGG16*, *ResNet50* e *EfficientNetB0*, destacando-se pela eficiência da combinação entre a arquitetura *ConvNeXtTiny* e a otimização AGBO.

Com base nos trabalhos relacionados, observou-se a existência de diversos algoritmos de classificação de glaucoma, porém sem ferramentas gratuitas com interface gráfica que os integrem. Assim, este projeto visa desenvolver um sistema com essa funcionalidade, unindo técnicas de aprendizado profundo a uma aplicação prática completa. O trabalho diferencia-se por integrar modelos de redes neurais convolucionais (CNNs) a uma interface gráfica intuitiva, banco de dados e API, possibilitando o uso real em triagens oftalmológicas. Além disso, emprega uma base de dados ampla (SMDG-19), com 12.449 imagens, e avalia comparativamente diferentes arquiteturas de CNNs (*ResNet152V2*, *DenseNet201*, *MobileNetV2* e *EfficientNetV2L*) sob múltiplas estratégias de treinamento e balanceamento de dados, destacando-se pela abordagem experimental abrangente e pela aplicabilidade prática do sistema desenvolvido.

3. MÉTODO PROPOSTO

Nesta seção, é descrita a metodologia seguida neste trabalho, que pode ser dividida em oito fases. Iniciou-se com o entendimento das ferramentas. Em seguida, foi realizado o levantamento bibliográfico. Com a base teórica estabelecida, partiu-se para a aquisição das imagens. Posteriormente, as imagens foram submetidas ao pré-processamento. Em seguida, foi realizada a extração das características. Com essas características extraídas, procedeu-se à classificação. Posteriormente, realizou-se a avaliação dos resultados. Em seguida, a construção da ferramenta. Por fim, ocorreu a integração da ferramenta. Um resumo visual da metodologia adotada pode ser encontrado na Figura 1.

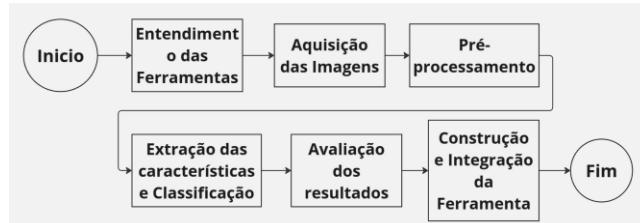


Figura 1. Fluxograma da metodologia.

3.1. Seleção das Tecnologias

Neste estágio, a meta estabelecida era adquirir conhecimento suficiente sobre as tecnologias empregadas para realizar os experimentos e criar a ferramenta sugerida. Optou-se pelo uso da linguagem *Python* para o desenvolvimento do software, dada sua eficácia e flexibilidade, atribuídas à vasta disponibilidade de bibliotecas. As ferramentas que foram exploradas e aplicados neste projeto incluem: *MongoDB*, *Numpy*, *pytorch*, *Matplotlib*, *PyQt5*, *Opencv*, *Pymongo* e *FastAPI*.

3.2. Aquisição das Imagens

Com a base teórica estabelecida, partiu-se para a aquisição das imagens, etapa essencial para reunir os dados necessários ao treinamento e validação do modelo.

Nessa etapa, foi realizada a aquisição das imagens para o projeto. A base de dados escolhida foi a SMDG-19 [6], que consiste na combinação de 19 conjuntos de dados públicos contendo imagens de fundo de olho relacionadas ao glaucoma. Essa base é reconhecida como o maior repositório público de imagens oculares com registros da doença. As imagens presentes na base estão organizadas em três categorias: sem glaucoma, com glaucoma e

suspeita, com um total de 7549 imagens sem glaucoma, 4767 com glaucoma e 133 suspeitas. Na Figura 2 é apresentado alguns exemplos de cada classe desta base.

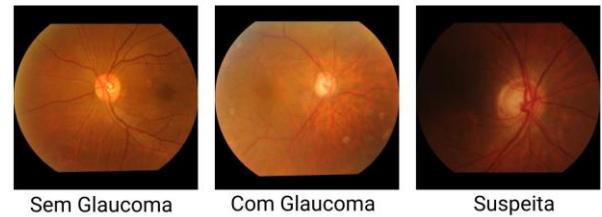


Figura 2. Exemplo de imagem de cada uma das classes da base SMDG-19.

Primeiramente, a classe “suspeito” foi excluída devido à quantidade reduzida de amostras, o que poderia comprometer o desempenho do modelo durante o treinamento. Com essa remoção, a base de dados passou a conter 12.449 imagens, divididas entre as classes com glaucoma e sem glaucoma. Para o treinamento foi adotado a distribuição de 80% das imagens para treinamento, 10% para validação e 10% para testes.

3.3. Pré-processamento

Posteriormente, as imagens foram submetidas ao pré-processamento, garantindo que estivessem devidamente preparadas para a próxima etapa.

Neste trabalho, foram aplicados diversos métodos de pré-processamento para aprimorar a qualidade das imagens de fundo ocular antes do uso dos modelos de classificação. As imagens foram inicialmente redimensionadas para a dimensão padrão de (224, 224), garantindo compatibilidade com a arquitetura dos modelos empregados no treinamento. Em seguida, foi realizada a normalização dos valores de pixel, ajustando-os para a escala entre 0 e 1. Essa etapa promove maior consistência nos dados e contribui para o melhor desempenho dos algoritmos de aprendizado profundo.

Devido ao desbalanceamento da base de dados, foi conduzido um treinamento inicial utilizando os dados em seu estado original. Para analisar a influência dessa disparidade entre as classes, foram implementadas técnicas de aumento de dados, que visaram equilibrar o número de amostras em cada classe. Entre essas técnicas, destacam-se a aplicação de *flip* vertical, *flip* horizontal e a combinação de ambos, que foram aplicadas apenas no conjunto de treinamento.

Antes da aplicação dessas técnicas, o conjunto de treinamento continha 6.039 imagens da classe sem glaucoma e 3.813 da classe com glaucoma. Após o balanceamento, ambas as classes passaram a contar com 6.039 imagens cada. O objetivo dessas transformações não era apenas ampliar o volume de dados disponíveis para o treinamento, mas também essas transformações ajudaram o modelo, aprendendo a identificar padrões de glaucoma mesmo em imagens modificadas, garantindo assim um treinamento eficaz.

3.4. Extração das características e Classificação

Nesta etapa, foi realizada a extração de características consideradas relevantes nas imagens, por meio do uso de redes neurais convolucionais (do inglês, *Convolutional Neural Network CNNs*).

Neste trabalho, foram utilizadas uma série de modelos baseados em aprendizado profundo, incluindo *ResNet152V2*, *DenseNet201*, *MobileNetV2* e *EfficientNetV2L*. Esses modelos demonstram excelente desempenho quando pré-treinados com a base de dados *ImageNet* [3] e têm produzido resultados notáveis em diversas aplicações de imagens médicas, conforme evidenciado nos trabalhos [12], [13], [10] e [1]. Para cada um dos modelos empregados, a etapa de *fine-tuning* permite capturar padrões complexos nas imagens.

Durante essa etapa, as imagens foram classificadas como sem glaucoma ou com glaucoma. Para isso, foi adicionado ao topo da rede neural uma camada de *Global Average Pooling* para dados 2D. Esta foi seguida por duas camadas densas: a primeira com 1024 unidades utilizando a função de ativação *ReLU*, e a segunda camada, projetada para corresponder ao número de classes, que são duas, utilizando função de ativação *softmax* para a classificação final. O treinamento foi realizado com *batch size* de 32, utilizando o otimizador Adam, com learning rate inicial de 0,0001 e decaimento de 0,1 a cada 7 épocas. Os experimentos foram conduzidos em uma GPU NVIDIA RTX 4090 (24 GB) e CPU Intel i9, com tempo médio de aproximadamente 3 horas por treinamento.

Para o treinamento foram utilizadas três abordagens sendo elas:

1. Treinamento por 20 épocas com as camadas de classificação descongeladas.
2. Treinamento por 20 épocas com as últimas camadas da CNN descongeladas, variando o número de camadas conforme o modelo.
3. Um treinamento inicial de 5 épocas com as camadas de classificação descongeladas, seguido por um treinamento abrangente de 20 épocas com todas as camadas descongeladas.

Essas etapas foram utilizadas para observar o efeito na aprendizagem e no desempenho dos modelos. Para a segunda abordagem, devido à diferença na quantidade de camadas entre os modelos avaliados, foram especificadas as camadas que serão descongeladas em cada modelo da seguinte maneira: as últimas 50 camadas para *ResNet152V2*, *DenseNet201* e *MobileNetV2*, enquanto para *EfficientNetV2L* serão as últimas 20 camadas.

3.5. Avaliação dos resultados

D. Na avaliação de modelos de classificação, diversas métricas são essenciais para entender a eficácia e a eficiência do modelo em prever resultados corretos.

Uma das métricas principais é a função de loss, ou perda, que mede o quanto distantes estão as previsões do modelo dos valores reais durante o treinamento. A acurácia é considerada uma das métricas diretas para avaliar o desempenho global de um modelo. Ela é definida como a proporção de previsões corretas, que incluem verdadeiros positivos (VP) e verdadeiros negativos (VN), em relação ao total de casos avaliados. Esta métrica também leva em conta os falsos positivos (FP) e falsos negativos (FN). A fórmula para calcular a acurácia é apresentada na seguinte Equação 1.

$$\text{acurácia} = \frac{VP+VN}{VP+FP+VN+FN} \quad (1)$$

A Área sob a Curva (AUC) ROC (*Receiver Operating Characteristic*) é uma métrica de desempenho para classificadores binários que mede a capacidade de discriminação do modelo. AUC varia de 0 a 1, onde um valor de 1 indica um modelo perfeito e 0.5 um modelo sem capacidade discriminativa. A curva ROC é uma representação gráfica do *trade-off* entre a taxa de verdadeiros

positivos e a taxa de falsos positivos em diferentes limiares de classificação.

A precisão é uma métrica que mede a exatidão das previsões positivas do modelo. Ela é particularmente útil quando as consequências de falsos positivos são mais significativas. A precisão é calculada pela fórmula apresentada na Equação 2.

$$\text{precisão} = \frac{VP}{VP+FP} \quad (2)$$

O *recall*, ou sensibilidade, mede a habilidade do modelo de identificar todas as instâncias relevantes em um conjunto de dados. Esta métrica é crítica quando é essencial capturar todos os casos positivos. A fórmula para calcular o *recall* será apresentada na Equação 3.

$$\text{recall} = \frac{VP}{VP+FN} \quad (3)$$

3.6. Construção e Integração da Ferramenta

Após validar os algoritmos, iniciou-se o desenvolvimento da ferramenta que incorpora os algoritmos discutidos anteriormente. No decorrer do desenvolvimento, utilizou-se o *Qt Designer* para elaborar as interfaces, o *MongoDBAtlas* para gerenciar o banco de dados *MongoDB*, e o *FastAPI* para criar a API responsável pela classificação das imagens de fundo óptico.

E por fim, foi feita implementação do algoritmo de detecção do glaucoma, procedeu-se com a integração da interface gráfica do usuário (GUI) que foi desenvolvida, com os algoritmos de visão computacional e aprendizado de máquina, empregando a biblioteca *PyQt5*.

4. Resultados e Discussão

Os resultados deste artigo representam uma análise detalhada do desempenho dos modelos de CNNs empregadas, além de uma ferramenta desenvolvida para a classificação do glaucoma em imagens retinianas.

Para a avaliação de desempenho dos modelos na classificação de glaucoma em imagens retinianas, foi utilizada algumas CNNs. Os modelos avaliados incluem *ResNet152V2*, *DenseNet201*, *MobileNetV2* e *EfficientNetV2L*.

Os resultados dos modelos são apresentados nas Tabelas 2 e 3, respectivamente, sem e com balanceamento das classes.

Tabela 2. Resultados sem o balanceamento das classes.

Modelo	Abo rd.	Loss	Acurá.	AUC	Precisão	Recall
<i>ResNet152V2</i>	1	0,71	80%	0,88	80%	80%
	2	0,78	83%	0,89	83%	83%
	3	0,59	78%	0,85	89%	85%
<i>DenseNet201</i>	1	0,40	84%	0,91	84%	84%
	2	0,57	85%	0,92	85%	85%
	3	0,53	86%	0,92	86%	86%
<i>MobileNetV2</i>	1	0,54	83%	0,89	83%	83%
	2	0,70	85%	0,90	85%	85%
	3	1,36	84%	0,87	84%	84%
<i>EfficientNetV2L</i>	1	0,65	61%	0,66	61%	61%
	2	0,58	69%	0,76	69%	69%
	3	0,59	68%	0,75	68%	68%

Tabela 3. Resultados com o balanceamento das classes.

Modelo	Abo rd.	Loss	Acurá.	AUC	Precisão	Recall
ResNet152V2	1	9,87	38%	0,38	38%	38%
	2	0,52	80%	0,89	80%	80%
	3	0,43	82%	0,91	82%	82%
DenseNet201	1	9,87	38%	0,38	38%	38%
	2	0,35	86%	0,94	86%	86%
	3	0,50	85%	0,91	85%	85%
MobileNetV2	1	0,45	82%	0,90	82%	82%
	2	1,70	61%	0,68	61%	61%
	3	0,48	85%	0,92	85%	85%
EfficientNetV2L	1	0,66	63%	0,66	63%	63%
	2	0,64	84%	0,67	64%	64%
	3	0,62	66%	0,70	66%	66%

Os resultados obtidos mostram que o modelo *DenseNet201* se destacou com os melhores valores de acurácia, AUC, precisão e *recall*. Esse desempenho pode ser explicado pela sua arquitetura mais profunda em comparação com os demais modelos. Além disso, a quantidade de amostras disponíveis possibilitou um treinamento eficaz, minimizando problemas de *overfitting*. O uso de data *augmentation* também melhorou a generalização do modelo.

Os modelos *ResNet152V2* e *MobileNetV2* também tiveram bons desempenhos, mas inferiores ao *DenseNet201*. O modelo *EfficientNetV2L* apresentou os piores resultados, indicando que sua arquitetura pode não ser adequada para essa tarefa específica.

Dessa forma, recomenda-se o uso do *DenseNet201*, pois obteve os melhores resultados na classificação de glaucoma em imagens intraoculares, seguido pelo *ResNet152V2* e *MobileNetV2*.

A ferramenta possui uma interface gráfica intuitiva e escalável, permitindo o processamento eficiente das imagens retinianas e a integração com sistemas de registros médicos eletrônicos. Abaixo são descritos os requisitos não funcionais, apresentados na Tabela 4, e os requisitos funcionais, presentes na Tabela 5, que correspondem a descrição dos serviços e restrições do sistema desenvolvido. A Figura 3 apresenta o diagrama de classes. E por fim são abordadas as funcionalidades das telas do sistema.

Tabela 4. Requisitos não Funcionais.

ID	Descrição	Categoria
RNF01	Limita o acesso às funcionalidades para usuários cadastrados.	Segurança
RNF02	Permite cadastro rápido de imagens sem informações do paciente.	Eficiência
RNF03	Aplicação <i>desktop</i> desenvolvida para Linux Ubuntu.	Portabilidade
RNF04	Processamento eficiente de imagens para auxiliar diagnóstico.	Eficiência
RNF05	Lida com grande volume de imagens sem comprometer desempenho.	Escalabilidade
RNF06	Interface intuitiva para profissionais de saúde.	Facilidade de Uso
RNF07	Garante segurança e privacidade dos dados do paciente.	Segurança

Tabela 5. Requisitos Funcionais.

ID	Descrição	Depende de
RF01	Cadastra, edita e remove os dados dos pacientes.	RNF02, RNF05
RF02	Permite buscas no histórico de operações.	RNF02, RNF05
RF03	Controle de cadastro evitando duplicações.	RNF02, RNF05
RF04	Interface gráfica intuitiva.	-
RF05	Acesso a todos os dados obtidos pelo sistema.	RNF02, RNF05
RF06	Suporte a imagens oftalmológicas (nervo óptico, retina, campo visual).	RNF02, RNF05
RF07	Classifica imagens conforme estágio do glaucoma usando IA.	-
RF08	Apresenta resultados de classificação de forma clara para médicos.	-
RF09	Integração com registros médicos eletrônicos (EMR).	-

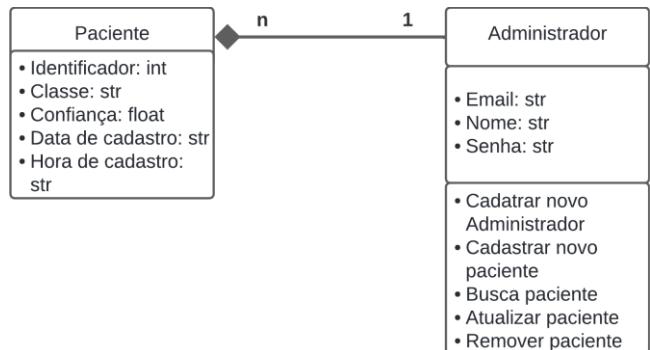


Figura 3. Diagrama de classes.

Figura 4: A tela de cadastro do administrador, possibilita o armazenamento dos dados do administrador após preencher todos os campos editáveis e pressionar o botão de cadastrar. Esta tela é composta pelos seguintes elementos: 1: Campos editáveis; 2: Botão de cadastrar; 3: Botão que abre a tela do administrador.

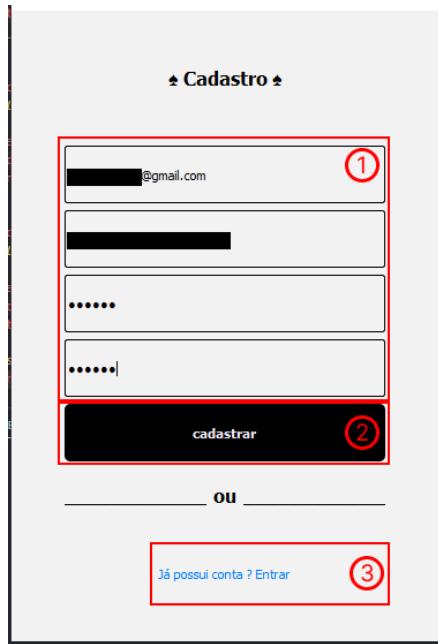


Figura 4. Janela de cadastro do administrador.

Figura 5: Apresenta a janela de login do administrador, que autentica o administrador e possibilita o acesso ao restante das funcionalidades do sistema. Esta tela é composta pelos seguintes elementos: 4: Campos editáveis para inserção dos dados do adm; 5: Botão de *login*; 6: Botão que abre a tela de cadastro do administrador.

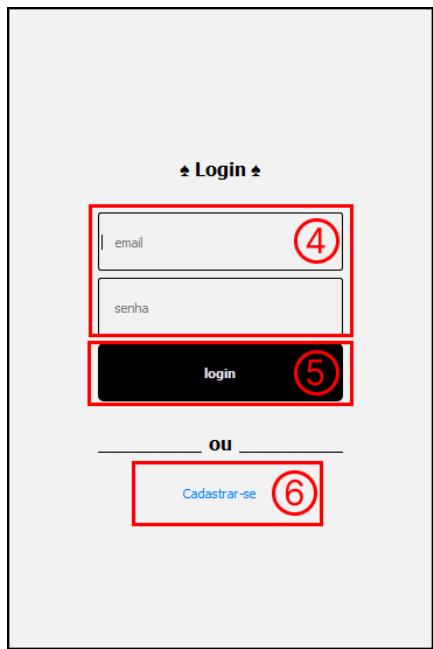


Figura 5. Janela de *login* do administrador.

Figura 6: Mostra a tela de menu inicial, onde é disponibilizado o histórico das operações de classificação de imagens internas do olho, e os botões das funcionalidades restantes. Esta tela é composta pelos seguintes elementos: 7: Nome do administrador logado; 8: Botão que abre a tela de cadastro do paciente; 9: Botão que abre a tela de busca, atualização e remoção de pacientes; 10: Botão de desconexão do administrador; 11: Histórico das operações de classificação de glaucoma.



Figura 6. Janela de menu inicial.

Figura 7: Mostra a janela de cadastro do identificador e imagem interna do olho do paciente. Esta tela é composta pelos seguintes elementos: 12: *Display* com imagem importada; 13: Botão de importação da imagem; 14: Botão de importação de um diretório de imagens; 15: Botão de geração de identificador de paciente; 16: Campo editável com para inserção do identificador do paciente; 17: Botão de classificação. 18: Botão que volta para o menu inicial.

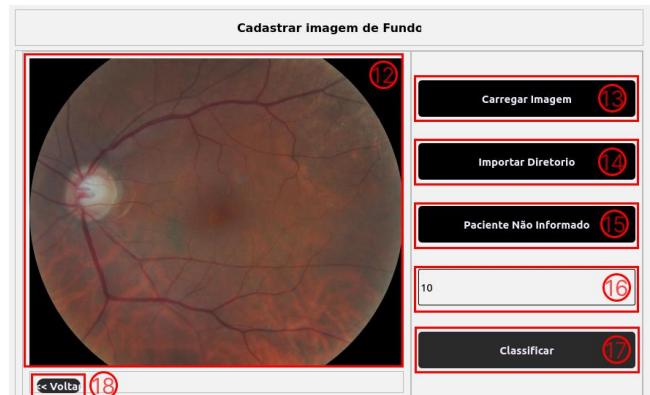


Figura 7. Realizando a operação de identificação de Indivíduo.

Figura 8: Mostra a janela de resultados da classificação da imagem de glaucoma. Esta tela é composta pelos seguintes elementos: 19: *Display* com imagens a imagem importada; 20: Campo com o resultado da classificação; 21: Campo com o identificador do paciente; 22: Botão de cadastro do paciente; 23: Botão de descarte dos dados do paciente.

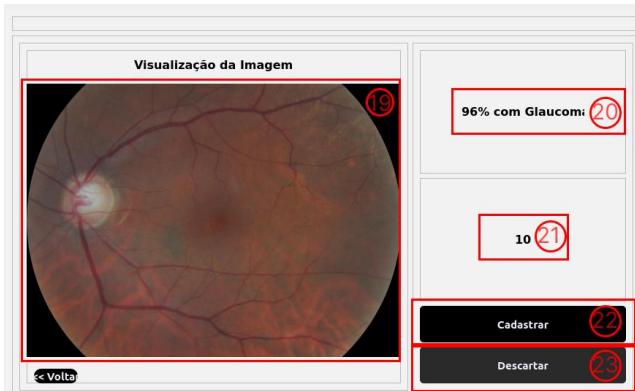


Figura 8. Realizando a operação de cadastro de Indivíduo.

Figura 9: Mostra a janela de edição de paciente, que possibilita a busca e a edição dos dados dos indivíduos cadastrados. Esta tela é composta pelos seguintes elementos: 24: Display com imagens a imagem importada; 25: Campo editável para a inserção do identificador do paciente; 26: Botão que realiza a busca do paciente, utilizando o identificador informado no campo editável 25; 27: Campo com o resultado da classificação; 28: Campo editável; 29: Botão que realiza a atualização dos dados modificados nos campos editáveis 28; 30: Botão que realiza a remoção dos dados do paciente, utilizando como chave o e-mail informado no campo editável 28.

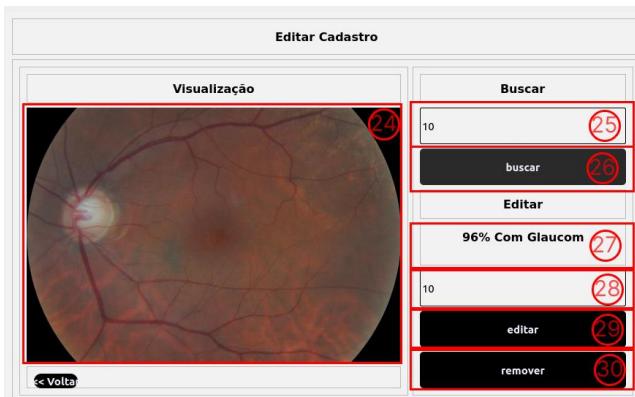


Figura 9. Janela de edição de indivíduo.

4.1. CONCLUSÃO

Este projeto teve como objetivo a criação de uma ferramenta para detecção que auxilie na detecção precoce do glaucoma por meio de análise de imagens de retina, utilizando técnicas de aprendizado profundo para identificar características significativas nas imagens do fundo ocular. A detecção precoce do glaucoma é fundamental, pois possibilita a intervenção rápida dos oftalmologistas, prevenindo a progressão da doença e melhorando a qualidade de vida dos pacientes.

Neste trabalho, a arquitetura *DenseNet201* se destacou na atividade de diagnóstico de glaucoma, superando outros modelos em acurácia, AUC, precisão e *recall*, tanto com quanto sem *data augmentation*, tornando-se a escolha recomendada para a integração na aplicação final desse trabalho. O sistema foi desenvolvido em *Python*, utilizando *PyQt* e *FastAPI* para construir uma interface interativa e eficiente.

Apesar dos resultados promissores, este estudo apresenta algumas limitações, como a exclusão da classe “suspeito” no processo de classificação, a ausência de um módulo de segmentação para destacar regiões de interesse na retina e a falta de validação clínica direta com especialistas.

Para futuras pesquisas, recomenda-se explorar novas arquiteturas de CNNs e investigar abordagens alternativas de classificação de glaucoma, que possam ser integradas à interface existente. Além disso, é sugerido implementar modelos de segmentação para identificar áreas de interesse, visando aprimorar a precisão do método de classificação. Por fim, recomenda-se a realização de uma demonstração prática ou de um estudo clínico para validar o desempenho do sistema em um contexto real de aplicação.

5. REFERÊNCIAS

1. M. Ali, M. Shahroz, U. Akram, M. F. Mushtaq, S. C. Altamiranda, S. A. Obregon, I. D. L. T. Díez, and I. Ashraf. Pneumonia detection using chest radiographs with novel efficientnetv2l model. *IEEE Access*, 2024.
2. D. Das, D. R. Nayak, S. V. Bhandary, and U. R. Acharya. Cdam-net: Channel shuffle dual attention based multi-scale cnn for efficient glaucoma detection using fundus images. *Engineering Applications of Artificial Intelligence*, 133:108454, 2024.
3. J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei. Imagenet: A large-scale hierarchical image database. In *2009 IEEE conference on computer vision and pattern recognition*, pages 248–255, 2009.
4. G. D’Souza, P. C. Siddalingaswamy, and M. A. Pandya. Alternet-k: a small and compact model for the detection of glaucoma. *Biomedical Engineering Letters*, 14(1):23–33, 2024.
5. S. S. Hayreh. Neovascular glaucoma. *Progress in Retinal and Eye Research*, 26(5):470–485, 2007.
6. R. Kiefer, M. Abid, M. R. Ardila, J. Steen, and E. Amjadian. A catalog of public glaucoma datasets for machine learning applications: A detailed description and analysis of public glaucoma datasets available to machine learning engineers tackling glaucoma-related problems using retinal fundus images and oct images. In *Proceedings of the 2023 7th International Conference on Information System and Data Mining*, 2023.
7. B. P. Makala and D. M. Kumar. An efficient glaucoma prediction and classification integrating retinal fundus images and clinical data using dncnn with machine learning algorithms. *Results in Engineering*, page 104220, 2025
8. M. Melo Ferreira, G. Braz Junior, J. D. Sousa de Almeida, and A. Cardoso Paiva. Glaucoma grading using multimodal imaging and multilevel cnn. *IEEE Latin America Transactions*, 21(10):1095–1102, 2023.
9. H. A. Quigley and A. T. Broman. The number of people with glaucoma worldwide in 2010 and 2020. *British Journal of Ophthalmology*, 90(3):262–267, 2006.
10. Z. Riaz, B. Khan, S. Abdullah, S. Khan, and M. S. Islam. Lung tumor image segmentation from computer tomography images using mobilenetv2 and transfer learning. *Bioengineering*, 10(8):981, 2023.
11. A. Roy, A. Sen, S. Gupta, S. Haldar, S. Deb, T. N. Vankala, and A. Das. Deepyeyenet: Adaptive genetic bayesian algorithm

- based hybrid convnexttiny framework for multi-feature glaucoma eye diagnosis. *arXiv preprint arXiv:2501.11168*, 2025.
- 12. C. H. Salh and A. M. Ali. Unveiling breast tumor characteristics: A resnet152v2 and mask r-cnn based approach for type and size recognition in mammograms. *Traitemet du Signal*, 40(5):1821, 2023.
 - 13. H. A. Sanghvi, R. H. Patel, A. Agarwal, S. Gupta, V. Sawhney, and A. S. Pandya. A deep learning approach for classification of covid and pneumonia using densenet-201. *International Journal of Imaging Systems and Technology*, 33(1):18–38, 2023.
 - 14. I. M. Silva. Diagnóstico do glaucoma congênito–revisão sistemática, 2016.