

Bruno Macedo Sanches

**Biblioteca de algoritmos de Machine Learning  
para o Diagnóstico do Glaucoma**

São Paulo, SP

2023



Bruno Macedo Sanches

# **Biblioteca de algoritmos de Machine Learning para o Diagnóstico do Glaucoma**

Trabalho de conclusão de curso apresentado  
ao Departamento de Engenharia de Computação e Sistemas Digitais da Escola Politécnica  
da Universidade de São Paulo para obtenção  
do Título de Engenheiro.

Universidade de São Paulo – USP

Escola Politécnica

Departamento de Engenharia de Computação e Sistemas Digitais (PCS)

Orientador: Prof. Dr. Edson Satoshi Gomi

São Paulo, SP

2023

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

#### Catálogo-na-publicação

Sanches, Bruno Macedo  
Biblioteca de algoritmos de Machine Learning para o Diagnóstico do  
Glaucoma / B. M. Sanches -- São Paulo, 2023.  
60 p.

Trabalho de Formatura - Escola Politécnica da Universidade de São  
Paulo. Departamento de Engenharia de Computação e Sistemas Digitais.

1.Glaucoma 2.Deep Learning 3.Machine Learning 4.Generative  
Adversarial Networks I.Universidade de São Paulo. Escola Politécnica.  
Departamento de Engenharia de Computação e Sistemas Digitais II.t.

# Agradecimentos

Gostaria de expressar meus sinceros agradecimentos a todos que contribuíram para o desenvolvimento e conclusão deste projeto. Agradeço profundamente ao Professor Dr. Edson Satoshi Gomi, que generosamente aceitou me orientar neste projeto, mesmo com pouco tempo disponível para a sua conclusão. À minha família, que tem sido um pilar fundamental ao longo de toda a minha jornada acadêmica. Um agradecimento especial à Daiane, minha parceira, por sua constante colaboração na revisão e sugestões nos documentos. Também quero expressar minha gratidão a todos os colegas e amigos que encontrei ao longo da graduação na Escola Politécnica, cuja amizade espero levar para toda a vida. Muito obrigado a todos pelo apoio e contribuições que tornaram este projeto possível.



# Resumo

O Glaucoma é uma doença que afeta milhões de pessoas em todo o mundo, e a única forma de evitar a progressão da doença é através da detecção e tratamento precoce. Na literatura, vários estudos já validaram a utilização de algoritmos de Deep Learning para a detecção e classificação de Glaucoma a partir de Fotografias de Fundo de Olho, Tomografia de Coerência Ótica e Exames de Campo Visual, mas estes algoritmos muitas vezes não estão disponíveis publicamente. Neste trabalho, procuramos implementar arquiteturas validadas de forma a criar uma biblioteca de algoritmos e métodos que possam ser utilizados em futuros trabalhos na área. Foram implementados três algoritmos de detecção de glaucoma, obtendo-se métricas superiores a 0,93 AUROC, 0,9 Precisão e F1. Foi também implementado um algoritmo de segmentação semântica de discos ópticos, que atingiu AUROC superior a 0,96, e foi estudada a implementação de Redes Gerativas Adversárias para a geração de conjuntos de dados de Tomografia de Coerência Ótica, que sofreu ajustes de compatibilidade e usabilidade. As implementações atingiram o objetivo de criar uma biblioteca de algoritmos que poderá ser utilizada em trabalhos futuros para comparação de novas técnicas e algoritmos.

**Palavras-chave:** Glaucoma. Deep Learning. GAN.



# Abstract

Glaucoma is a disease that affects millions of people worldwide, and the only way to prevent the disease from progressing is through early detection and treatment. In the literature, several studies have already validated the use of Deep Learning algorithms for the detection and classification of Glaucoma from Fundus Photographs, Optical Coherence Tomography and Visual Field Examinations, but these algorithms are often not publicly available. In this work, we want to implement validated architectures in order to create a library of algorithms and methods that can be used in future work in the area. Three glaucoma detection algorithms were implemented, achieving metrics of over 0.93 AUROC, 0.9 Accuracy and F1. An optical disk semantic segmentation algorithm was also implemented, which achieved AUROC of over 0.96, and the implementation of Generative Adversarial Networks for the generation of Optical Coherence Tomography datasets was studied, which underwent compatibility and usability adjustments. The implementations achieved the goal of creating a library of algorithms that can be used in future work as a comparison of new techniques and algorithms.

**Keywords:** Glaucoma. Deep Learning. GAN.



# Lista de ilustrações

Figura 1 – Anatomia do olho . . . . .	24
Figura 2 – Fotografia de Fundo do Olho . . . . .	30
Figura 3 – Imagens retiradas dos datasets utilizados para classificação. . . . .	33
Figura 4 – Ilustração do processo de <i>Data Augmentation</i> . . . . .	34
Figura 5 – Exemplo de Curva ROC. . . . .	37
Figura 6 – Modelo para segmentação do disco óptico . . . . .	38
Figura 7 – Função de perda para o modelo de segmentação do disco óptico . . . . .	39
Figura 8 – AUROC para o modelo de segmentação do disco óptico . . . . .	39
Figura 9 – Imagem segmentada e recortada ao redor do disco óptico. . . . .	40
Figura 10 – Evolução da função de perda durante o treinamento das redes. . . . .	41
Figura 11 – Evolução da acurácia durante o treinamento das redes. . . . .	42
Figura 12 – Evolução da F1-Score durante o treinamento das redes. . . . .	43
Figura 13 – Evolução da AUROC durante o treinamento das redes. . . . .	44
Figura 14 – Curva ROC para os modelos treinados. . . . .	45
Figura 15 – Função de perda para os modelos GAN. . . . .	48
Figura 16 – Imagens geradas pela GAN. . . . .	49
Figura 17 – Função de perda para os modelos WGAN. . . . .	49
Figura 18 – Imagens geradas pela WGAN. . . . .	50
Figura 19 – Arquitetura da Rede Geradora . . . . .	59
Figura 20 – Arquitetura da Rede Discriminadora . . . . .	60



# Lista de tabelas

Tabela 1 – Modelos a serem implementados para a classificação de glaucoma . . . .	32
Tabela 2 – Datasets utilizados para a tarefa de detecção de glaucoma. . . . .	32
Tabela 3 – Resultados de cada modelo testado. . . . .	43
Tabela 4 – Versões anteriores e atuais das ferramentas utilizadas. . . . .	47



# Lista de abreviaturas e siglas

AAO	<i>American Academy of Ophthalmology</i>
ACGAN	<i>Generative Adversarial Networks with Auxiliary Classifier</i>
ANN	<i>Artificial Neural Network</i>
AUROC	<i>Area Under Receiver Operating Characteristic</i>
DATASUS	Departamento de Informática do Sistema Único de Saúde
GAN	<i>Generative Adversarial Networks</i>
GPAА	Glaucoma Primário de Ângulo Aberto
GPAF	Glaucoma Primário de Ângulo Fechado
GPU	<i>Graphics Processing Unit</i>
IA	Inteligência Artificial
MLP	<i>Multi-Layer Perceptron</i>
OCT	<i>Optical Coherence Tomography</i>
OMS	Organização Mundial da Saúde
PIO	Pressão intraocular
ROC	<i>Receiver Operating Characteristic</i>
SUS	Sistema Único de Saúde
WGAN	<i>Wasserstein Generative Adversarial Network</i>



# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>17</b>
<b>1.1</b>	<b>Motivação</b>	<b>17</b>
<b>1.2</b>	<b>Objetivo</b>	<b>17</b>
<b>1.3</b>	<b>Justificativa</b>	<b>18</b>
<b>1.4</b>	<b>Organização</b>	<b>18</b>
<b>2</b>	<b>ASPECTOS CONCEITUAIS</b>	<b>21</b>
<b>2.1</b>	<b>O que é Glaucoma ?</b>	<b>22</b>
<b>2.2</b>	<b>Anatomia do Olho e Glaucoma</b>	<b>23</b>
2.2.1	Estruturas principais	24
2.2.1.1	Córnea	24
2.2.1.2	Esclera	24
2.2.1.3	Câmara Anterior e Humor Aquoso	25
2.2.1.4	Íris	25
2.2.1.5	Cristalino	25
2.2.1.6	Retina	26
2.2.1.7	Disco Óptico	26
<b>2.3</b>	<b>Tipos de Glaucoma</b>	<b>26</b>
2.3.1	Glaucoma de Ângulo Aberto	26
2.3.1.1	Glaucoma de Ângulo Fechado	27
2.3.1.2	Glaucoma Primário	27
2.3.1.3	Glaucoma Secundário	27
<b>2.4</b>	<b>Diagnóstico e Exames de Detecção</b>	<b>28</b>
2.4.1	Tonometria	28
2.4.2	Fotografia de fundo do olho	29
2.4.3	Tomografia de Coerência Óptica - OCT	30
<b>3</b>	<b>IMPLEMENTAÇÃO DAS REDES NEURAIS PARA O DIAGNÓSTICO DO GLAUCOMA</b>	<b>31</b>
<b>3.1</b>	<b>Escolha dos Modelos</b>	<b>31</b>
<b>3.2</b>	<b>Escolha dos Datasets</b>	<b>32</b>
<b>3.3</b>	<b>Pré-processamento</b>	<b>32</b>
3.3.1	Segmentação do disco óptico	32
3.3.2	<i>Data Augmentation</i>	34
<b>3.4</b>	<b>Treinamento</b>	<b>35</b>
3.4.1	Divisão dos dados entre treino e teste	35

<b>3.5</b>	<b>Métricas de avaliação de desempenho</b> . . . . .	<b>36</b>
3.5.1	Acurácia . . . . .	36
3.5.2	F1-Score . . . . .	36
3.5.3	AUROC . . . . .	37
<b>3.6</b>	<b>Frameworks utilizados</b> . . . . .	<b>38</b>
<b>3.7</b>	<b>Projeto e Implementação</b> . . . . .	<b>38</b>
3.7.1	Segmentação do disco óptico . . . . .	38
3.7.2	Detecção de Glaucoma . . . . .	40
<b>3.8</b>	<b>GANs - Redes Gerativas Adversárias</b> . . . . .	<b>44</b>
3.8.1	Desenvolvimento e Resultados . . . . .	46
3.8.1.1	Refatoração da base de código para compatibilidade . . . . .	46
3.8.1.2	Geração de imagens de OCT . . . . .	47
<b>3.9</b>	<b>Análise dos Resultados</b> . . . . .	<b>49</b>
<b>4</b>	<b>CONSIDERAÇÕES FINAIS</b> . . . . .	<b>51</b>
<b>4.1</b>	<b>Contribuições</b> . . . . .	<b>51</b>
<b>4.2</b>	<b>Perspectivas de Continuidade</b> . . . . .	<b>51</b>
	<b>REFERÊNCIAS</b> . . . . .	<b>53</b>
	<b>APÊNDICES</b> . . . . .	<b>57</b>
	<b>APÊNDICE A – ARQUITETURAS DE REDES NEURAIS UTILIZADAS PARA AS REDES GAN E WGAN</b> . . . . .	<b>59</b>

# 1 Introdução

## 1.1 Motivação

O projeto é motivado pela necessidade de avançar nas capacidades de detecção de glaucoma, uma doença ocular que afeta milhões de pessoas globalmente. Diante da importância do diagnóstico precoce para evitar danos irreversíveis, surgiu o interesse em explorar abordagens inovadoras baseadas em inteligência artificial, especificamente em Machine Learning e Deep Learning. A literatura científica na área fornece métodos validados, porém, suas implementações frequentemente não são acessíveis publicamente, destacando a carência de uma biblioteca aberta para essas tarefas.

Assim, a motivação principal é criar e disponibilizar publicamente uma biblioteca de algoritmos que aborde a detecção de glaucoma, baseando-se nas implementações realizadas em (DIAZ-PINTO et al., 2019), cujo trabalho valida o uso de algoritmos convolucionais em diversos datasets, além de prover um dataset próprio de fotografias de fundo de olho. Por sua vez, (OLIVEIRA, 2021) utiliza arquiteturas de Redes Gerativas Adversárias para a geração de dados de Tomografias de Coerência Óptica, ampliando a quantidade de dados disponíveis que podem ser utilizados para treinar classificadores e obter melhores resultados. O projeto busca superar os desafios existentes, não apenas implementando com sucesso métodos específicos, mas também abordando questões de compatibilidade e usabilidade de bases de código já existentes, garantindo durabilidade e facilitando futuras pesquisas na área.

## 1.2 Objetivo

O propósito fundamental deste estudo é realizar a implementação e testes de redes neurais descritas na literatura, que foram avaliadas para a classificação de imagens relacionadas ao glaucoma. O objetivo deste trabalho é criar uma biblioteca abrangente de algoritmos destinada a beneficiar alunos e pesquisadores interessados na detecção de glaucoma, oferecendo a capacidade de desenvolver e comparar soluções com base em um conjunto de redes bem estabelecidas. As redes a serem implementadas incluem a pioneira AlexNet(KRIZHEVSKY; SUTSKEVER; HINTON, 2012), introduzida para a classificação de imagens, a renomada VGG16(SIMONYAN; ZISSERMAN, 2015), e a inovadora ResNet50(HE et al., 2015), notável por suas conexões residuais. Para essa análise, utilizaremos diversos datasets de imagens de fundo de olho, como o ACRIMA(DIAZ-PINTO et al., 2019), composto por 705 imagens de pacientes saudáveis e portadores de glaucoma, juntamente com outros conjuntos de dados relevantes, como o BEH(ISLAM et

al., 2022), RIM-ONE(BATISTA et al., 2020), e Drishti-GS(SIVASWAMY et al., 2014). Essa abordagem busca fornecer uma base sólida para futuras pesquisas em detecção de glaucoma e promover o compartilhamento de recursos valiosos na comunidade científica.

Além disso, busca-se também experimentar algoritmos de Redes Gerativas Adversárias - GANs - no contexto de detecção de Glaucoma a partir de Tomografias de Coerência Óptica - OCTs. Neste caso, o objetivo é explorar o algoritmo para a geração de novos dados, aumentando a quantidade disponível para o treinamento de redes neurais e alcançando melhores métricas de classificação.

### 1.3 Justificativa

A justificativa para a realização deste trabalho é fundamentada na necessidade de preencher uma lacuna significativa na pesquisa relacionada ao diagnóstico do glaucoma por meio de redes neurais convolucionais. Embora diversos artigos científicos tenham avaliado o potencial das arquiteturas de redes, como VGG16 e ResNet50, para a classificação de imagens relacionadas ao glaucoma, poucos deles disponibilizaram suas implementações práticas e modelos treinados. Esta lacuna representa uma barreira para a replicabilidade e avanço da pesquisa nesse campo.

A disponibilização de uma biblioteca de modelos pré-treinados baseados nessas arquiteturas se revela de grande utilidade para futuras investigações, uma vez que proporcionará às comunidades acadêmica e científica acesso a ferramentas de alto desempenho para a detecção de glaucoma. Além disso, a criação da biblioteca permitirá a padronização e a comparação direta de resultados entre diferentes estudos, contribuindo para o progresso mais eficaz e confiável no campo da detecção de glaucoma.

Portanto, este trabalho visa preencher a lacuna existente na disponibilidade de implementações práticas de arquiteturas de redes neurais e, assim, promover a colaboração e o avanço da pesquisa relacionada ao glaucoma, fornecendo uma plataforma sólida para futuras investigações nessa área crítica da saúde ocular.

### 1.4 Organização

A estrutura deste trabalho está organizada da seguinte maneira:

- Capítulo 2: Neste capítulo, são introduzidos os conceitos teóricos do glaucoma e suas características.
- Capítulo 3: No terceiro capítulo, são detalhadas as metodologias que serão aplicadas no desenvolvimento dos modelos e na avaliação dos resultados. Também é apresentado

o desenvolvimento do projeto em si, incluindo a implementação das redes neurais e a análise dos resultados obtidos.

- Capítulo 4: No sexto capítulo, destacam-se as considerações finais, lições aprendidas e perspectivas futuras deste trabalho.



## 2 Aspectos Conceituais

A visão é um dos sentidos mais preciosos para a humanidade, desempenhando um papel vital em nossa compreensão e interação com o mundo ao nosso redor. No entanto, a saúde ocular nem sempre é garantida, e doenças como o glaucoma representam desafios significativos para a qualidade de vida das pessoas. O glaucoma é uma doença ocular crônica, incurável, que afeta milhões de indivíduos em todo o mundo, com implicações graves para a saúde visual e a qualidade de vida.

De acordo com estudos recentes (THAM et al., 2014), estima-se que, em 2020, o glaucoma tenha afetado cerca de 76 milhões de pessoas globalmente, com uma projeção alarmante de 111,8 milhões de casos até 2024. O glaucoma é especialmente prevalente entre aqueles com mais de 40 anos, e a pesquisa revela que aproximadamente 3,54% da população mundial entre 40 e 80 anos sofre dessa doença. A incidência varia consideravelmente de acordo com o tipo de glaucoma, com o Glaucoma Primário de Ângulo Aberto (GPAA) prevalecendo na África (4,20%) e o Glaucoma Primário de Ângulo Fechado (GPAF) sendo mais comum na Ásia (1,09%).

Além disso, fatores como gênero, etnia e ambiente urbano ou rural desempenham papéis significativos nas taxas de incidência. Homens têm uma probabilidade 1,36 vezes maior de desenvolver GPAA do que mulheres, enquanto a população afrodescendente apresenta uma chance 2,80 vezes maior de desenvolver a doença em comparação com os eurodescendentes. Pessoas que vivem em áreas urbanas também têm uma probabilidade 1,58 vezes maior de desenvolver glaucoma do que aquelas que residem em zonas rurais.

Dado o desenvolvimento gradual e assintomático do glaucoma ao longo da vida de um paciente, meses ou até anos podem passar despercebidos antes que ocorra um impacto perceptível na visão. A tragédia é que, se não for diagnosticado e tratado precocemente, o glaucoma pode levar à cegueira irreversível. Portanto, a consulta regular ao oftalmologista desempenha um papel crítico na detecção precoce por meio de exames oftalmológicos e no início do tratamento, evitando assim a cegueira.

O objetivo deste trabalho é aproveitar os avanços recentes em Deep Learning para criar um sistema de detecção de glaucoma, capaz de identificar com precisão casos da doença desde o seu estágio inicial. Isso possibilitará um tratamento rápido e eficaz, salvaguardando a visão dos pacientes.

Neste capítulo, apresentaremos os mecanismos do olho e do glaucoma, incluindo seus diferentes tipos. Além disso, discutiremos os métodos de diagnóstico e as opções de tratamento disponíveis para combater essa doença debilitante.

## 2.1 O que é Glaucoma ?

A Academia Americana de Oftalmologia (AAO) define o glaucoma da seguinte maneira:

O glaucoma é uma doença que danifica o nervo óptico do olho. Normalmente ocorre quando o líquido se acumula na parte frontal do olho. Esse líquido adicional aumenta a pressão no olho, causando danos ao nervo óptico. (BOYD, 2023, tradução nossa)

Essa definição engloba duas características essenciais do glaucoma. A primeira delas é o dano ao nervo óptico, que é o sintoma primário da doença e a principal causa de cegueira. A segunda característica é o acúmulo de líquido, conhecido como humor aquoso, no olho, sendo este processo, na maioria dos casos, o responsável pelo dano progressivo ao nervo óptico.

O Glaucoma também pode ser caracterizado pelo aumento da Pressão Intraocular (PIO), que é um fator de risco importante para o desenvolvimento de Glaucoma de Ângulo Aberto, e que pode ocorrer por diversos motivos, sendo o principal o acúmulo do humor aquoso no olho.

Outros fatores de risco que contribuem para o desenvolvimento do glaucoma incluem características demográficas, como idade e ancestralidade. Populações afrodescendentes e indivíduos com idade superior a 40 anos apresentam um risco mais elevado de contrair a doença. Além disso, um histórico familiar positivo da doença é considerado também um fator de risco, uma vez que fatores genéticos podem resultar em pressão intraocular elevada (PIO) e, conseqüentemente, danos ao nervo óptico.

No contexto brasileiro, um levantamento realizado por (GAVA et al., 2022) com base nos dados obtidos no Departamento de Informática do Sistema Único de Saúde (DATASUS-SUS), referentes ao período de 2017 a 2022, revela um total de 33.035 novos diagnósticos de glaucoma durante esse intervalo. Notavelmente, aproximadamente 80% desses casos (26.708) ocorreram em pacientes com 40 anos ou mais, e mais da metade (52%) afetou indivíduos do sexo masculino.

O estudo também destaca o impacto diferenciado do glaucoma em diferentes grupos populacionais. A população negra foi a mais afetada, representando 30,9% dos novos casos (10.224), o que equivale a 4,6 vezes a prevalência observada na população branca (2.196). Adicionalmente, os grupos de população negra e parda em conjunto compreenderam 56% dos novos casos (18.652).

Embora tenham sido levantados outros fatores, como a região geográfica e o nível de escolaridade, as discrepâncias observadas podem ser, em grande parte, atribuídas a diferenças na distribuição demográfica entre as regiões e nos níveis de escolaridade. No entanto, esses dados ressaltam a importância de abordagens específicas para a detecção

precoce e o tratamento do glaucoma, levando em consideração as disparidades entre grupos populacionais no Brasil.

Além do impacto individual da doença, o glaucoma exerce uma influência significativa sobre os recursos financeiros da sociedade. Um estudo conduzido por (VARMA et al., 2011) nos Estados Unidos revela que os custos diretos associados a aproximadamente 2 milhões de pacientes com glaucoma chegam a cerca de US\$ 2,9 bilhões. No entanto, o estudo sugere que esse valor pode ser substancialmente maior devido a casos não diagnosticados. Os custos diretos englobam principalmente despesas relacionadas ao uso de medicamentos, procedimentos médicos e cirúrgicos, além de alguns custos não médicos, como treinamento e uso de cães guia, transporte e cuidados especializados. Quando se consideram os custos indiretos associados à perda de produtividade no trabalho e aos dias de trabalho perdidos devido a consultas médicas, o custo total para a sociedade pode se elevar a patamares ainda mais significativos.

Devido à natureza incurável do tipo mais comum de glaucoma, o GPAA, o tratamento é direcionado principalmente para evitar a progressão da doença, com foco na redução da Pressão Intraocular (PIO). As abordagens terapêuticas abrangem o uso de colírios, métodos cirúrgicos não invasivos, como tratamento a laser, e procedimentos invasivos quando necessário. Em um estudo conduzido por (KASS et al., 2002), os autores estimaram que pacientes com PIO elevada que utilizaram colírios hipotensores tinham 0,4 vezes menos probabilidade de desenvolver casos de GPAA em comparação com pacientes que não utilizaram colírios. Esse estudo ressalta a importância do diagnóstico precoce e do tratamento da PIO elevada, mesmo antes do surgimento dos sintomas da doença, como meio de evitar a progressão para estágios mais graves.

## 2.2 Anatomia do Olho e Glaucoma

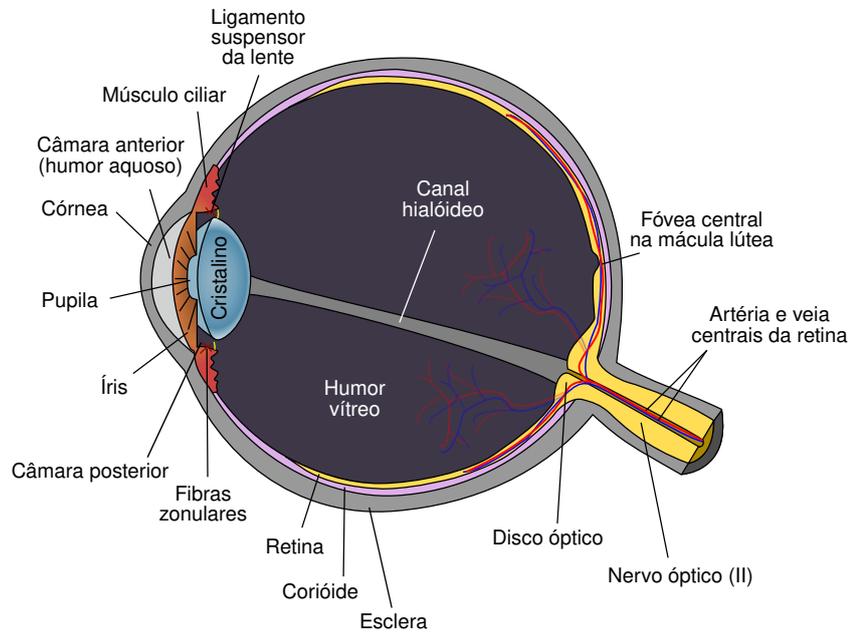
Para entender o funcionamento do glaucoma, é necessário entender a anatomia do olho, as estruturas presentes e como a alteração dessas estruturas estão ligadas ao aparecimento e desenvolvimento do glaucoma.

O olho é dividido em dois segmentos principais (Conselho Brasileiro de Oftalmologia, ):

1. **Segmento Anterior:** Engloba todas as estruturas diante do cristalino, incluindo este.
2. **Segmento Posterior:** O Segmento posterior é dividido em duas câmaras:
  - a) Câmara anterior: Espaço compreendido entre a Córnea e a Íris.
  - b) Câmara posterior: Espaço compreendido entre a Íris e o Cristalino.

A Figura 1 mostra a anatomia do olho e algumas de suas estruturas principais.

Figura 1 – Anatomia do olho



Fonte: (RHCASTILHOS, 2013)

## 2.2.1 Estruturas principais

### 2.2.1.1 Córnea

A córnea é a seção mais frontal do olho, uma estrutura transparente que desempenha um papel fundamental na proteção do olho e na focalização da luz para formar a imagem na retina. Composta por cinco camadas distintas, a córnea inclui o Epitélio, as Membranas de Bowman, o Stroma, as Membranas de Descemet e o Endotélio, cada uma com funções específicas destinadas a proteger o olho contra micro-organismos e manter sua hidratação adequada (WELLS; GRASSMEYER; AWH, ).

### 2.2.1.2 Esclera

A esclera é uma camada fibrosa de cor branca opaca que constitui a porção comumente conhecida como o 'Branco do Olho'. Ela é revestida por uma membrana transparente chamada conjuntiva. A função primária da esclera é a proteção do olho, além de manter sua forma e volume. Ela desempenha um papel importante na integridade estrutural do globo ocular (WELLS; GRASSMEYER; AWH, ).

### 2.2.1.3 Câmara Anterior e Humor Aquoso

A Câmara Anterior é o espaço localizado entre o endotélio da córnea e a íris. Nesse espaço, passa-se o Humor Aquoso.

O Humor Aquoso é um líquido transparente composto por eletrólitos diluídos em água. Ele é produzido continuamente pelos processos ciliares e percorre várias estruturas oculares, incluindo a pupila e a Câmara Anterior ([Conselho Brasileiro de Oftalmologia,](#) ). Sua principal função é manter a homeostase das estruturas internas do olho.

O Humor Aquoso é continuamente produzido e drenado. A maior parte desse processo ocorre pela Câmara Anterior em direção à circulação sanguínea, enquanto uma pequena parcela é drenada pela Íris ([Conselho Brasileiro de Oftalmologia,](#) ).

É importante ressaltar que o Humor Aquoso desempenha um papel crucial na regulação da pressão intraocular (PIO). Quando o escoamento do Humor Aquoso é prejudicado, ocorre o acúmulo desse líquido, resultando em um aumento na PIO ([Conselho Brasileiro de Oftalmologia,](#) ).

### 2.2.1.4 Íris

A íris é uma estrutura colorida em formato circular localizada no interior do olho, e no centro da íris encontra-se uma abertura denominada pupila. Ela é uma parte fundamental do sistema de adaptação à luz do olho.

A íris é composta por músculos que funcionam para dilatar ou contrair a pupila. Quando exposta a ambientes com luz intensa, os músculos da íris contraem a pupila, reduzindo a quantidade de luz que penetra no olho e protegendo a retina da exposição excessiva à luz. Em ambientes com pouca luz, a íris dilata a pupila, permitindo uma maior entrada de luz para uma visão mais nítida em condições de baixa luminosidade ([BOYD; TURBERT, 2023](#)).

### 2.2.1.5 Cristalino

O cristalino é uma lente biconvexa, transparente e flexível localizada no interior do olho, situada entre a íris e o humor vítreo. Sua função primordial é ajustar o foco da luz que entra no olho. Essa capacidade de mudança de forma do cristalino é essencial para o processo de acomodação visual. À medida que os músculos ciliares se contraem ou relaxam, o cristalino se adapta, permitindo que os raios de luz sejam focalizados de maneira precisa na retina. Isso possibilita que objetos em diferentes distâncias sejam percebidos com clareza([BOYD; TURBERT, 2023](#)).

### 2.2.1.6 Retina

A retina, localizada na região posterior do olho, desempenha um papel fundamental na percepção visual. Sua função primordial consiste em captar a luz incidente e convertê-la em sinais elétricos, que são subsequentemente transmitidos ao sistema nervoso por meio do nervo óptico. Essa camada de tecido neural é composta por dois tipos principais de células especializadas em detectar estímulos luminosos: os cones e os bastonetes. Eles são responsáveis por processar informações visuais em diferentes condições de iluminação.

### 2.2.1.7 Disco Óptico

O disco óptico é uma região na retina do olho onde as fibras nervosas da retina se reúnem e formam o nervo óptico. Sua aparência característica inclui uma escavação central, devido à ausência de fotorreceptores nessa área. Essa escavação é uma característica anatômica normal do disco óptico, mas seu tamanho e forma podem variar entre indivíduos.

O disco óptico desempenha um papel fundamental na avaliação e diagnóstico do glaucoma. Durante um exame oftalmológico, o oftalmologista avalia o disco óptico em busca de quaisquer alterações, como aumento da escavação, perda de fibras nervosas ou atrofia do nervo óptico. Essas mudanças podem ser indicativas de dano causado pelo glaucoma, uma vez que o aumento da PIO crônica pode levar à compressão das fibras nervosas, resultando em danos irreversíveis.

## 2.3 Tipos de Glaucoma

### 2.3.1 Glaucoma de Ângulo Aberto

O tipo mais comum de glaucoma é o de Ângulo Aberto. Essa variante do glaucoma é caracterizada pela obstrução das vias de escoamento do Humor Aquoso na Câmara Anterior do olho.

Nesse tipo de glaucoma, a obstrução dessas vias de drenagem causa uma dificuldade no escoamento do Humor Aquoso, resultando no seu acúmulo na câmara anterior. Consequentemente, isso leva a um aumento progressivo da pressão intraocular, que pode danificar a seção posterior do olho, incluindo o nervo óptico. É importante destacar que o glaucoma de ângulo aberto é uma condição tipicamente assintomática nas fases iniciais, o que significa que os pacientes muitas vezes não percebem a perda gradual de visão que ocorre. Infelizmente, quando os sintomas se tornam evidentes, a doença já atingiu um estágio avançado.

A detecção precoce e o tratamento adequado são essenciais para controlar o glaucoma de ângulo aberto e evitar danos irreversíveis à visão. Profissionais de saúde ocular realizam exames oftalmológicos regulares para monitorar a pressão intraocular e

avaliar a saúde do disco óptico, o que ajuda a identificar o glaucoma em estágios iniciais, antes que a visão seja gravemente comprometida. Portanto, a conscientização sobre essa condição e a busca de atenção médica adequada são vitais na prevenção do glaucoma de ângulo aberto.([JINDAL et al., 2023](#); [MAHABADI; FORIS; TRIPATHY, 2022](#))

### 2.3.1.1 Glaucoma de Ângulo Fechado

O Glaucoma de Ângulo Fechado é uma condição em que a obstrução da passagem do humor aquoso ocorre devido ao deslocamento da íris em direção à abertura que se encontra entre a íris e o cristalino, bloqueando a passagem do humor aquoso. Esse fechamento súbito da via de drenagem do humor aquoso resulta em um aumento acentuado e rápido da pressão intraocular (PIO).

À medida que a PIO eleva-se rapidamente a níveis elevados, a pressão excessiva no interior do olho pode causar danos imediatos ao nervo óptico. Diferentemente do glaucoma de ângulo aberto, o glaucoma de ângulo fechado é frequentemente sintomático, com os pacientes experimentando dor ocular intensa, visão embaçada, halos em torno das luzes e náuseas. Esses sintomas agudos exigem atenção médica imediata.

O glaucoma de ângulo fechado é uma situação de emergência oftalmológica, e o tratamento precoce é fundamental para aliviar a pressão intraocular e prevenir danos permanentes ao nervo óptico. A correção geralmente envolve procedimentos médicos ou cirúrgicos para criar uma passagem adequada para o humor aquoso e normalizar a pressão intraocular. Portanto, a pronta identificação dos sintomas e a busca de atendimento médico são cruciais para o manejo bem-sucedido do glaucoma de ângulo fechado e a preservação da visão ([KHAZAENI; KHAZAENI, 2023](#)).

### 2.3.1.2 Glaucoma Primário

O glaucoma primário é uma condição ocular crônica caracterizada por danos progressivos ao nervo óptico e perda de campo visual. É denominado "primário" porque não está associado a uma causa clara e identificável do dano ao nervo óptico ([National Eye Institut, 2021](#)).

### 2.3.1.3 Glaucoma Secundário

O glaucoma secundário é uma forma da doença que surge como uma consequência de outras condições oftalmológicas ou fatores subjacentes. Diferentemente do glaucoma primário, no qual não há uma causa clara identificável, o glaucoma secundário pode ser rastreado até condições específicas que afetam o fluxo do humor aquoso e resultam em aumento da pressão intraocular (PIO) ([National Eye Institut, 2021](#)).

Existem vários subtipos de glaucoma secundário, cada um associado a condições oftalmológicas ou situações distintas que interferem no fluxo do humor aquoso. Alguns exemplos incluem:

- **Glaucoma Neovascular:** Essa forma de glaucoma se desenvolve quando ocorre neovascularização do olho, ou seja, o crescimento anormal de novos vasos sanguíneos. Esses novos vasos podem obstruir as vias de drenagem do humor aquoso, levando a um aumento na PIO.
- **Glaucoma Pigmentar:** No glaucoma pigmentar, o pigmento da íris descama e se acumula nas estruturas oculares, interferindo no fluxo do humor aquoso. Esse acúmulo pode aumentar a pressão intraocular.
- **Glaucoma Exfoliativo:** O glaucoma exfoliativo está associado à presença de materiais exfoliativos nos olhos, que podem obstruir as vias de drenagem do humor aquoso e resultar em aumento da PIO.
- **Glaucoma Uveítico:** O glaucoma uveítico é caracterizado pela presença de inflamação ocular crônica, conhecida como uveíte, que pode obstruir as vias de drenagem do humor aquoso e levar ao aumento da PIO.

É importante ressaltar que o glaucoma secundário é frequentemente resultado de outras condições oftalmológicas ou sistêmicas, como diabetes, inflamações oculares, trauma ocular e uso de certos medicamentos. A identificação da causa subjacente e o tratamento adequado da condição primária são essenciais para o manejo bem-sucedido do glaucoma secundário ([National Eye Institut, 2021](#)).

## 2.4 Diagnóstico e Exames de Detecção

O diagnóstico do glaucoma pode ser realizado por meio de diversas abordagens e exames especializados. Estes procedimentos abrangem a avaliação da Pressão Intraocular (PIO) por meio da tonometria, a análise direta do dano ao nervo óptico usando técnicas como a imagem do fundo do olho e a tomografia de coerência óptica (OCT), bem como a avaliação do campo de visão, uma vez que as lesões glaucomatosas frequentemente se manifestam por meio da perda da visão periférica. Cada um desses métodos desempenha um papel fundamental na identificação precoce e na monitorização do glaucoma, permitindo um diagnóstico preciso e a implementação de medidas terapêuticas adequadas.

### 2.4.1 Tonometria

A tonometria é um exame que visa medir a pressão intraocular do olho. Ao longo da história, diversos pesquisadores identificaram uma relação entre a PIO (ou, em alguns

casos, a rigidez do olho) e o desenvolvimento de cegueira incurável. Com o passar do tempo, foram desenvolvidas técnicas para medir essa pressão, que passou a ser reconhecida como um dos principais fatores de risco para o glaucoma (STAMPER, 2011).

O método mais comum de tonometria utilizado hoje é o tonômetro de Goldmann. Essa técnica se baseia no princípio da Aplanção, que estabelece uma relação entre a pressão intraocular e a força necessária para achatar uma pequena área da córnea. No tonômetro de Goldmann, a força necessária para deformar uma área de  $3.06\text{mm}^2$  da córnea é calculada (SALIM et al., 2022).

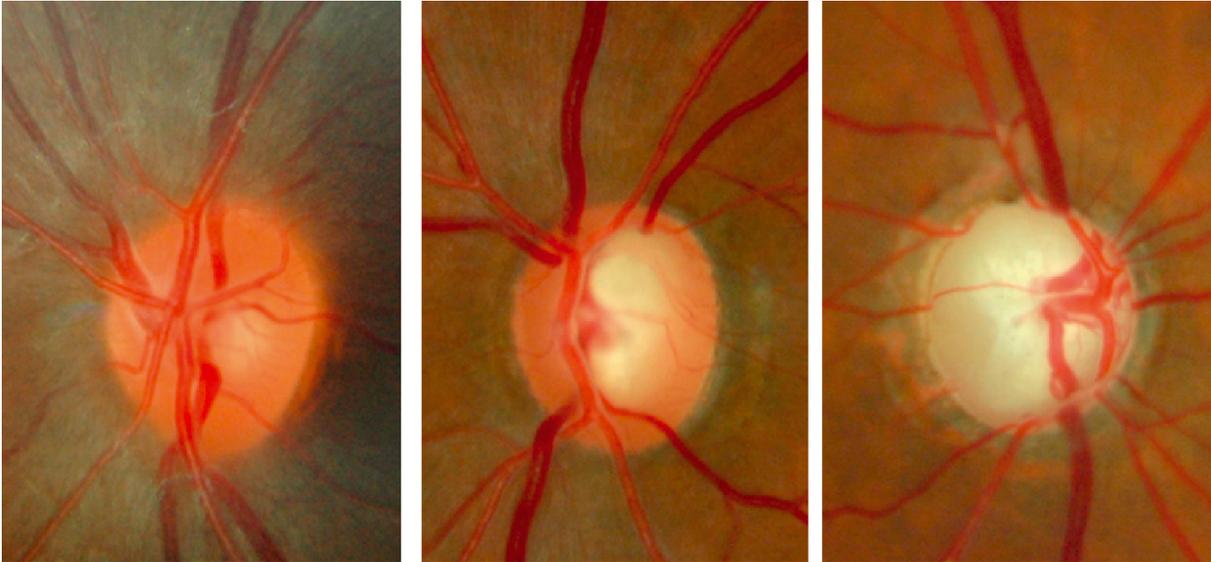
Métodos de Aplanção são afetados pela espessura da córnea. O design do tonômetro de Goldmann assume uma espessura média da córnea de 520 micrômetros, que pode variar consideravelmente em casos reais, introduzindo assim uma fonte de erro nas medições da pressão intraocular. Outros métodos de aplanção sem contato também estão disponíveis, como o método de sopro de ar, que emite uma coluna de ar gradualmente para deformar a córnea. A força de deformação é medida para determinar a pressão intraocular. No entanto, esses métodos podem apresentar imprecisões, e várias medições são frequentemente necessárias para obter uma medida mais precisa e com menor margem de erro (SALIM et al., 2022).

#### 2.4.2 Fotografia de fundo do olho

Outro método de diagnóstico do glaucoma envolve a fotografia do fundo do olho. Desenvolvida na década de 1920, essa técnica é amplamente utilizada hoje para avaliar os danos causados pelo glaucoma no nervo óptico. A fotografia do fundo do olho é valiosa por proporcionar uma visualização direta do interior do olho, permitindo uma avaliação qualitativa dos danos. No entanto, devido à sua natureza mais qualitativa do que quantitativa, a interpretação dos resultados depende da habilidade do profissional que analisa o exame (FELDMAN et al., 2022).

A Figura 2 exibe três fotografias do fundo do olho: uma saudável e duas com diferentes estágios de glaucoma. Uma característica proeminente nessas imagens é a capacidade de visualizar o *cup*, que se refere à área central ou à depressão no centro do disco óptico. Em casos de glaucoma, o *cup* pode aumentar de tamanho, muitas vezes devido à perda de fibras nervosas nessa região. Isso é um dos indicadores que os médicos usam para diagnosticar e monitorar o glaucoma, uma vez que o aumento do *cup* pode ser um sinal de dano ao nervo óptico causado pela doença. Portanto, a relação entre o tamanho do *cup* e o disco óptico é um dos fatores considerados pelos oftalmologistas durante o diagnóstico e acompanhamento do glaucoma. Quanto maior o *cup* em relação ao disco óptico, maior a preocupação quanto à possibilidade de glaucoma (OSAGUONA, 2016).

Figura 2 – Três fotografias do fundo do olho: à esquerda, um olho saudável; no centro, um olho com glaucoma moderado, evidenciando um aumento na área da depressão do nervo óptico, conhecida como *Cup* em inglês; à direita, um olho com glaucoma severo, onde a depressão do nervo óptico ocupa praticamente toda a área do disco óptico.



Fonte: ([HEALTH, 2013](#))

A Fotografia de Fundo de Olho é um indicador crucial no diagnóstico e detecção do glaucoma. Muitas aplicações de Inteligência Artificial (IA) utilizam conjuntos de dados formados por essas imagens para identificar o desenvolvimento de lesões glaucomatosas nos pacientes.

### 2.4.3 Tomografia de Coerência Óptica - OCT

A Tomografia de Coerência Óptica é mais um método crucial para detectar e diagnosticar o glaucoma e avaliar danos no nervo óptico. Essa técnica teve seu início com o desenvolvimento de interferômetros, dispositivos que coletam informações por meio da interferência da luz. As técnicas contemporâneas utilizam a Transformada de Fourier para decompor os comprimentos de onda e obter informações no domínio espectral, chamadas de *Spectral Domain - Optical Coherence Tomography*, ou SD-OCT([CHEEMA; AREF; MOORE, 2022](#)).

## 3 Implementação das Redes Neurais para o Diagnóstico do Glaucoma

Este capítulo concentra-se nas etapas relacionadas à implementação de redes neurais no diagnóstico de glaucoma. São abordadas as escolhas de modelos e arquiteturas, detalhes sobre os datasets utilizados e os procedimentos adotados durante o treinamento. Ao final, os resultados obtidos são apresentados e discutidos.

### 3.1 Escolha dos Modelos

A tarefa de classificação de glaucoma envolve o uso de imagens de fundo do olho, como na Figura 2 para a detecção de glaucoma, que serão disponibilizados na biblioteca de algoritmos.

Para esta tarefa foram escolhidos 3 arquiteturas de rede. A escolha das redes VGG16, VGG19 e ResNet50 para o projeto foi fundamentada em sua eficácia comprovada em tarefas de classificação de imagens e detecção de padrões. As redes neurais convolucionais VGG16 e VGG19, propostas em (SIMONYAN; ZISSERMAN, 2015), são conhecidas por sua arquitetura relativamente simples, consistindo em camadas convolucionais profundas com pequenos filtros, o que permite a extração de características detalhadas das imagens. A ResNet50, proposta em (HE et al., 2015), introduziu o conceito de blocos residuais, que ajudam a superar problemas de degradação do desempenho à medida que as redes se tornam mais profundas. Esse design permitiu a construção de redes mais profundas e eficientes, sendo especialmente útil quando a complexidade da tarefa de classificação é elevada.

Além disso, essas arquiteturas foram escolhidas com base em seu desempenho comprovado em conjunto com conjuntos de dados grandes e diversificados, o que é crucial para o sucesso de modelos de aprendizado profundo. A utilização de arquiteturas pré-treinadas proporciona benefícios significativos quando se lida com conjuntos de dados médicos limitados, permitindo o uso de *transfer learning* para adaptar modelos treinados em grandes conjuntos de dados de imagens para a tarefa específica de detecção de glaucoma.

Dessa forma, a escolha dessas arquiteturas foi respaldada pela sua eficiência em tarefas semelhantes, pela sua capacidade de extração de características relevantes e pela facilidade de adaptação para o contexto específico da detecção de glaucoma.

Modelo	Fonte
VGG16	(SIMONYAN; ZISSERMAN, 2015)
VGG19	(SIMONYAN; ZISSERMAN, 2015)
ResNet50	(HE et al., 2015)

Tabela 1 – Modelos a serem implementados para a classificação de glaucoma

## 3.2 Escolha dos Datasets

Para esta tarefa, foram utilizados 5 datasets diferentes, todos eles anotados por profissionais da saúde. Cada dataset passou por um processo de pré-processamento, detalhado a seguir. A seleção desses datasets levou em consideração sua disponibilidade pública e a presença de anotações realizadas por profissionais da saúde treinados, minimizando potenciais riscos relacionados a anotações incorretas. A Tabela 2 detalha os datasets e as quantidades de pontos de dados para cada classe.

Dataset	# Positivos	# Negativos	# Total	Fonte
ACRIMA	394	309	703	(DIAZ-PINTO et al., 2019)
Drishti-GS	68	30	98	(SIVASWAMY et al., 2014)
HRF	15	15	30	(BUDAI et al., 2013)
sjchoi86-HRF	101	300	401	(ABBAS, 2017)
RIM-ONE	172	313	485	(BATISTA et al., 2020)
Total	750	967	1717	-

Tabela 2 – Datasets utilizados para a tarefa de detecção de glaucoma.

## 3.3 Pré-processamento

Esta seção descreve os métodos de pré-processamento adotados para preparar os dados para uso nas arquiteturas testadas. Dentre esses métodos, destaca-se o processo de recorte do disco óptico, visando reduzir as imagens e selecionar apenas a informação relevante para o diagnóstico de glaucoma.

### 3.3.1 Segmentação do disco óptico

Este trabalho segue a abordagem sugerida por (DIAZ-PINTO et al., 2019), onde as imagens foram otimizadas cortando-se em torno do disco óptico. Assim, apenas a seção correspondente ao disco óptico foi utilizada como entrada para a rede neural, em vez da imagem completa. Para realizar essa segmentação, a técnica proposta por (XU et al., 2017) foi adotada. Os autores utilizaram de rede neural pré-treinada capaz de segmentar a imagem entre o disco óptico e o restante. A partir do disco óptico segmentado, o centro de massa dos pixels classificados como pertencentes ao disco óptico é calculado segundo as Equações 3.1 e 3.2.

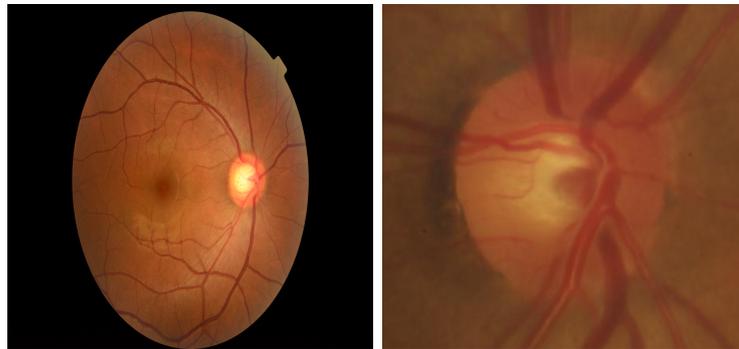
Figura 3 – Imagens retiradas dos datasets utilizados para classificação.



(a) Acrima

(b) Drishti-GS

(c) HRF



(d) sjchoi86-HRF

(e) RIM-ONE

Fonte: Acrima (DIAZ-PINTO et al., 2019), Drishti-GS (SIVASWAMY et al., 2014), HRF (BUDAI et al., 2013), sjchoi86-HRF (ABBAS, 2017), RIM-ONE (BATISTA et al., 2020).

$$\bar{x} = \frac{\sum_{i,j} i \cdot M_{ij}}{\sum_{i,j} M_{ij}} \quad (3.1)$$

$$\bar{y} = \frac{\sum_{i,j} j \cdot M_{ij}}{\sum_{i,j} M_{ij}} \quad (3.2)$$

onde  $M_{ij}$  representa o valor do pixel, 1 se corresponde ao disco óptico e 0 se não.

Em (LONG; SHELHAMER; DARRELL, 2015), destaca-se a eficácia do emprego de redes convolucionais na tarefa de segmentação de imagens. Seguindo essa abordagem, optou-se por utilizar a arquitetura ResNet50(HE et al., 2015), pré-treinada na tarefa de segmentação semântica no extenso conjunto de dados COCO, visando capitalizar o conhecimento prévio adquirido durante o treinamento em um conjunto diversificado de imagens.

A etapa subsequente envolveu a adaptação da arquitetura para a tarefa específica de classificação binária, seguida pelo treinamento (*transfer learning*) da ResNet50 para essa finalidade. Para tal, o conjunto de dados ORIGA(ZHANG et al., 2010) foi empregado,

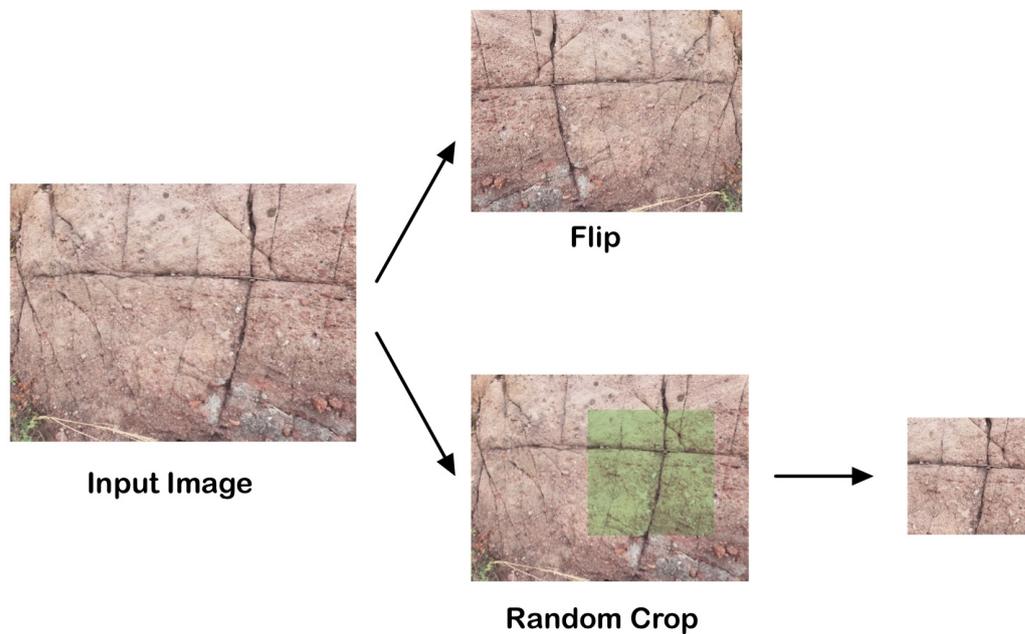
composto por 650 imagens anotadas por profissionais da saúde treinados no Instituto de Pesquisas Oftalmológicas de Singapura.

O processo de *transfer learning* não apenas aproveita o conhecimento prévio da ResNet50, mas também ajusta a arquitetura para otimizar seu desempenho na classificação binária de imagens oftalmológicas. Essa estratégia visa alcançar uma melhor adaptação da rede à tarefa específica em questão.

### 3.3.2 Data Augmentation

Devido ao reduzido número de imagens, optou-se por empregar o método de *Data Augmentation*, cuja principal finalidade é aumentar artificialmente a quantidade de dados utilizados no treinamento da rede por meio de transformações nas imagens. O método é abordado em (PEREZ; WANG, 2017), onde os experimentos indicam um aumento significativo na acurácia final da rede quando comparado ao treinamento sem a utilização desse método.

Figura 4 – Ilustração do processo de Data Augmentation através de transformações na imagem.



Fonte: (TSEKICHUN, 2021)

No projeto, foram adotadas três transformações principais:

1. **Rotação aleatória:** Um valor entre 0 e 180 é aleatoriamente selecionado, e a imagem é rotacionada de acordo com esse valor em graus.
2. **Espelhamento horizontal aleatório:** A imagem é espelhada aleatoriamente no eixo horizontal, com uma probabilidade  $pp$  de 0,5.
3. **Espelhamento vertical aleatório:** A imagem é espelhada aleatoriamente no eixo vertical, com uma probabilidade  $pp$  de 0,5.

Essas transformações foram incorporadas porque, em um contexto real, as imagens obtidas podem apresentar rotações ou reflexões em comparação com o dataset utilizado para o treinamento. Outras transformações, como *jitter*, mudanças de brilho e contraste, fazem menos sentido, uma vez que dificilmente essas condições variam com base no retinógrafo utilizado.

## 3.4 Treinamento

Os pesos da rede foram adquiridos pré-treinados no conjunto de dados ImageNet. Dessa forma, realizou-se uma estratégia de *transfer learning*, consistindo na substituição da última camada da rede, inicialmente uma camada linear com 1000 neurônios (associada a 1000 classes de saída), por uma camada linear composta por apenas um neurônio, apropriando-se da natureza do problema de classificação binária.

A função de perda empregada foi a *Binary Cross-Entropy*, conforme detalhado na equação 3.3. Para a atualização dos pesos, optou-se pelo algoritmo de *Stochastic Gradient Descent* (Gradiente Descendente Estocástico), que realiza atualizações em passos proporcionais e na direção contrária ao gradiente da função de perda em relação aos pesos da rede. A taxa de aprendizado (*learning rate*) utilizada foi de  $1 * 10^{-4}$ , e um momento de 0.9 também foi empregado.

$$\text{BCELoss}(\hat{y}, y) = -[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})] \quad (3.3)$$

Adicionalmente, empregou-se uma estratégia de mini-batches, onde batches de tamanho 8 foram utilizados durante o treinamento. O processo de treinamento foi conduzido ao longo de 100 épocas, e métricas foram registradas a cada época para avaliação do desempenho do modelo.

### 3.4.1 Divisão dos dados entre treino e teste

Com o intuito de aprimorar a avaliação das métricas de desempenho da rede e identificar potenciais casos de overfitting, procedeu-se à divisão dos dados em conjuntos de

treino e teste. A estratificação dessa divisão foi realizada considerando a prevalência das classes negativas e positivas em cada dataset, preservando, assim, a proporção de diferentes tipos de imagens que podem ser derivadas de cada conjunto de dados. O conjunto de treino compreende 80% das imagens, enquanto o conjunto de teste abrange os restantes 20%. A proporção entre exemplos positivos e negativos é mantida para cada dataset.

Por exemplo, considerando a tabela 2 e utilizando o dataset sjchoi86-HRF (ABBAS, 2017) como referência, onde o número de dados representa aproximadamente 23% do total do conjunto de dados e os exemplos positivos constituem 25% desse dataset, os conjuntos de treino e teste foram estratificados de modo a manter essa proporção. Portanto, o conjunto de treino é composto por cerca de 23% de exemplos desse dataset, dos quais 25% são exemplos positivos específicos desse dataset.

## 3.5 Métricas de avaliação de desempenho

Para avaliar e comparar o desempenho dos modelos, foram escolhidas três métricas: Acurácia, F1-Score, *Area Under the Receiver Operating Characteristic* (AUROC).

### 3.5.1 Acurácia

A acurácia é uma métrica comum utilizada no contexto de classificação binária para avaliar o desempenho de um modelo. Ela mede a proporção de predições corretas em relação ao total de predições feitas pelo modelo. A Equação 3.4 demonstra como se forma o cálculo da acurácia.

$$\text{Acurácia} = \frac{\text{Número de predições corretas}}{\text{Total de predições}} \quad (3.4)$$

A acurácia varia de 0 a 1, sendo 1 indicativo de um desempenho perfeito, onde todas as predições do modelo são corretas, e 0 indicativo de um desempenho muito ruim, onde nenhuma predição é correta.

### 3.5.2 F1-Score

O F1-Score é uma métrica que combina precisão (a proporção de verdadeiros positivos em relação ao total de predições positivas), definida na Equação 3.5, e recall (a proporção de verdadeiros positivos em relação ao total de instâncias positivas), definida na Equação 3.6. Essa métrica é particularmente útil em situações de desbalanceamento de classes, como no caso de aplicações médicas, como a detecção de Glaucoma, onde a prevalência de casos positivos é inferior ao de casos negativos. A fórmula do F1-Score é dada pela Equação 3.7.

$$\text{Precisão} = \frac{\text{Verdadeiros Positivos}}{\text{Verdadeiros Positivos} + \text{Falsos Positivos}} \quad (3.5)$$

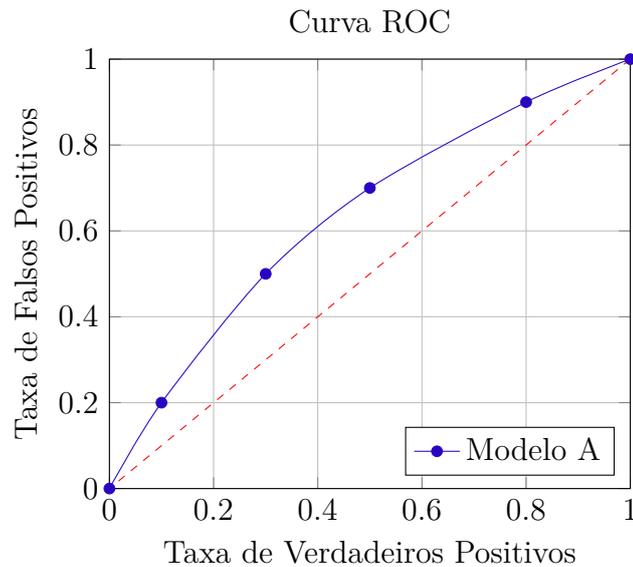
$$\text{Recall} = \frac{\text{Verdadeiros Positivos}}{\text{Verdadeiros Positivos} + \text{Falsos Negativos}} \quad (3.6)$$

$$F1\text{-Score} = \frac{2 \times \text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (3.7)$$

### 3.5.3 AUROC

A Curva ROC (Receiver Operating Characteristic) é uma representação gráfica que ilustra o desempenho de um modelo de classificação binária em diferentes limiares de decisão. A curva é construída plotando a taxa de verdadeiros positivos (sensibilidade) em relação à taxa de falsos positivos (1 - especificidade) para vários valores de limiar de classificação.

Figura 5 – Exemplo de Curva ROC.



Fonte: Autor.

A Área Sob a Curva ROC (AUROC) é uma métrica que avalia a capacidade discriminativa de um modelo de classificação binária em diferentes limiares de decisão. A Curva ROC, representada na Figura 5, ilustra a taxa de falsos positivos em função da taxa de verdadeiros positivos.

A AUROC é calculada como a área sob esta curva, sendo interpretada como uma medida global do desempenho do modelo. A fórmula para a AUROC não é diretamente expressa em termos de verdadeiros positivos ou falsos positivos, mas destaca a importância da relação entre sensibilidade e especificidade na avaliação do modelo.

Quanto maior a AUROC, melhor o desempenho do modelo na discriminação entre classes. A Figura 5 fornece uma representação visual desta métrica, sendo uma ferramenta valiosa na análise do comportamento do modelo em diferentes cenários de classificação.

## 3.6 Frameworks utilizados

Este projeto faz uso principalmente da biblioteca PyTorch(PASZKE et al., 2019), disponível para a linguagem Python 3(ROSSUM; DRAKE, 2009). Essa biblioteca permite a modelagem e treinamento de redes neurais profundas para diversas tarefas, além de possibilitar a paralelização dos cálculos por meio do uso de *Graphics Processing Units* - GPUs.

Para o treinamento de modelos, foi utilizada a ferramenta Google Colaboratory, que disponibiliza uma GPU NVIDIA T4 e permite grandes ganhos de desempenho ao paralelizar o treinamento em relação à execução somente na CPU.

O cálculo de métricas foi realizado através da biblioteca Scikit-Learn(BUITINCK et al., 2013), e os gráficos foram plotados com o uso da biblioteca Matplotlib(HUNTER, 2007).

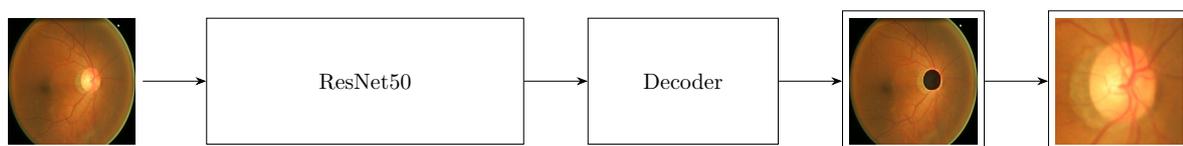
## 3.7 Projeto e Implementação

### 3.7.1 Segmentação do disco óptico

A primeira etapa de pré-processamento dos dados consiste na segmentação do disco óptico, a fim de recortar a imagem em torno dele. Esse procedimento auxilia a rede ao fornecer apenas as informações necessárias para a detecção do glaucoma.

Para realizar essa tarefa, foi implementada uma rede *Fully Convolutional Network* ResNet50 pré-treinada utilizando imagens do dataset COCO. Posteriormente, essa rede passou por um processo de *fine-tuning* utilizando o conjunto de dados ORIGA (ZHANG et al., 2010).

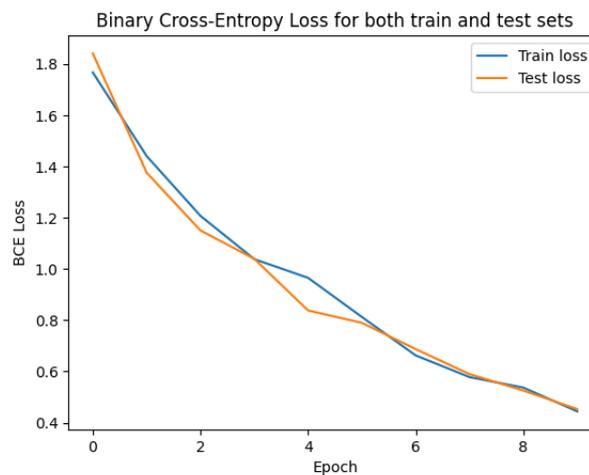
Figura 6 – Ilustração do modelo utilizado para segmentação do disco óptico.



Fonte: Autor

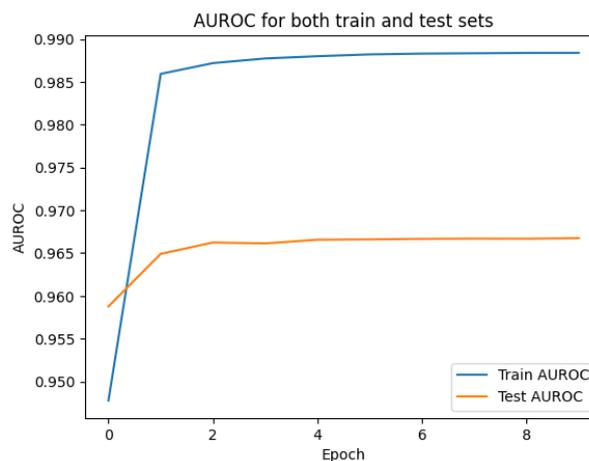
A Figura 6 ilustra o processo de recorte da imagem ao redor do disco óptico. Inicialmente, a imagem é introduzida em uma ResNet50, cuja saída é então processada por um decodificador. Nesse estágio, são atribuídos rótulos a cada pixel, e é importante observar que a função do decodificador é realizar o *UpSample* da imagem para sua resolução original.

Figura 7 – Evolução da função de perda durante as épocas de treinamento para o modelo de segmentação do disco óptico.



Fonte: Autor

Figura 8 – Evolução da AUROC durante as épocas de treinamento para o modelo de segmentação do disco óptico.



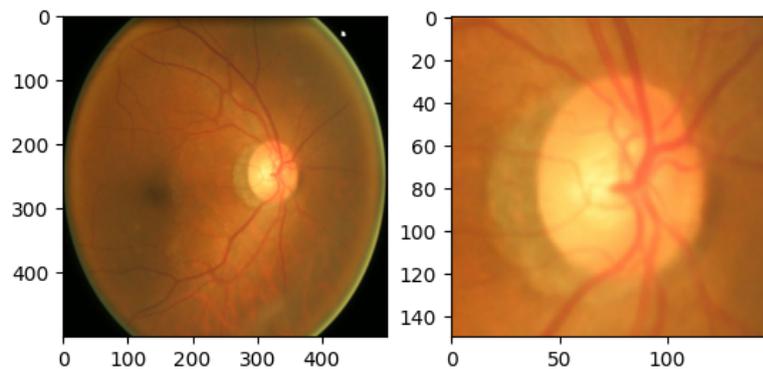
Fonte: Autor

Devido ao fato de a rede já ter sido pré-treinada em um extenso conjunto de dados de segmentação, o processo de *fine-tuning* para a tarefa de segmentação do disco óptico foi

simplificado. Esse aspecto pode ser observado nas Figuras 7 e 8, onde a função de perda diminui consistentemente, enquanto a curva AUROC permanece praticamente constante após poucas épocas. Foi considerado que a AUROC obtida no modelo, aproximadamente 0.965 no conjunto de testes, era adequada para realizar o pré-processamento das imagens antes de treinar a rede de classificação.

A partir deste modelo, o próximo passo foi a segmentação de todas as imagens que serão utilizadas no treino e teste do modelo de classificação. Nesse processo, as imagens foram segmentadas, e o centro de massa dos pixels classificados como pertencentes ao disco óptico foi calculado. Posteriormente, todas as imagens foram recortadas, seguindo o processo ilustrado na Figura 6.

Figura 9 – Imagem recortada automaticamente ao redor do disco óptico.



Fonte: Autor

A Figura 9 ilustra o resultado do sistema de recorte automático da imagem. O disco óptico é corretamente identificado e recortado, resultando em uma imagem mais útil para ser usada como entrada dos modelos.

### 3.7.2 Detecção de Glaucoma

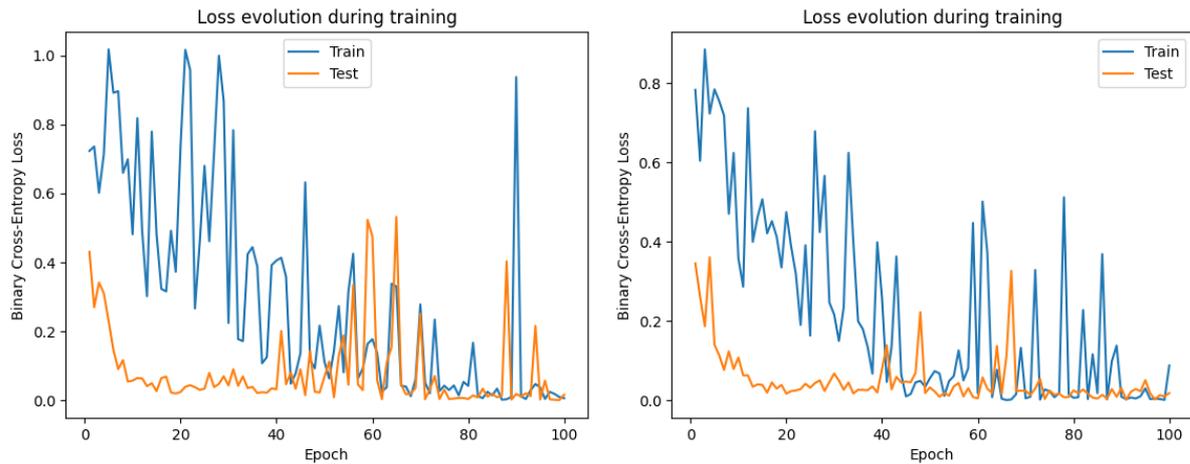
Após realizar o pré-processamento das imagens, a etapa seguinte foi treinar os três modelos propostos na Tabela 1 nos datasets descritos na Tabela 2.

Como especificado anteriormente, os dados foram divididos em 80% para treino e 20% para teste. As classes e datasets foram estratificados para representar, em proporção, os dados obtidos.

Além do recorte das imagens ao redor do disco óptico, foram aplicadas três transformações aleatórias de rotação e espelhamento, aumentando efetivamente o número de dados.

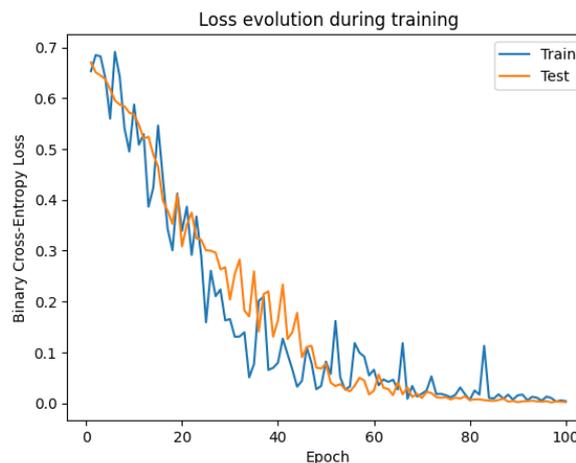
A Figura 10 exibe a função de perda das três arquiteturas estudadas: VGG16 e VGG19 (SIMONYAN; ZISSERMAN, 2015), além da ResNet50 (HE et al., 2015). Observa-se que todas as três arquiteturas convergem para um valor de perda bastante reduzido. No entanto, as arquiteturas VGG apresentam certa instabilidade nessa função. A hipótese para esse comportamento está relacionada ao uso do método de Dropout, aplicado na arquitetura ResNet50, mas não nas outras.

Figura 10 – Evolução da função de perda durante o treinamento das redes.



(a) VGG16

(b) VGG19

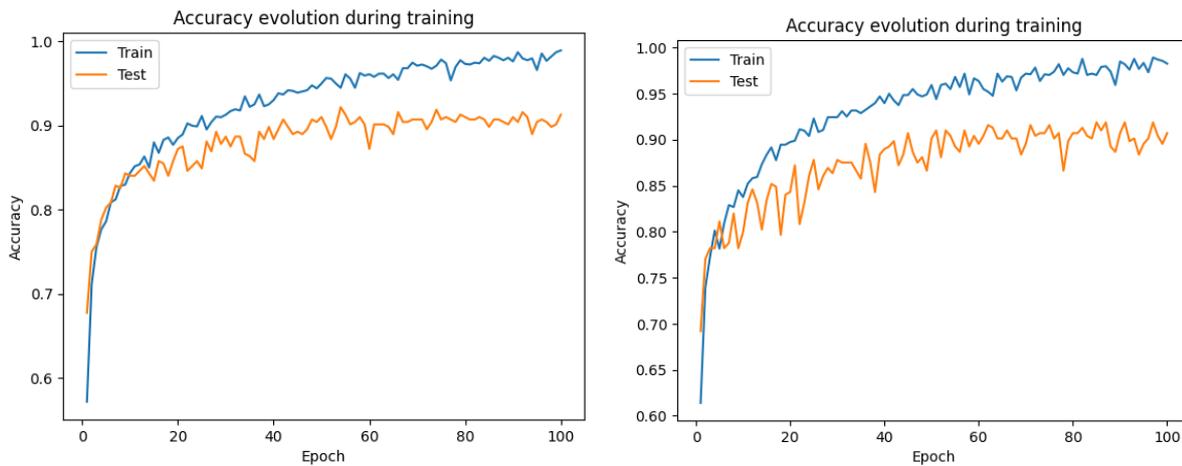


(c) ResNet50

Fonte: Autor.

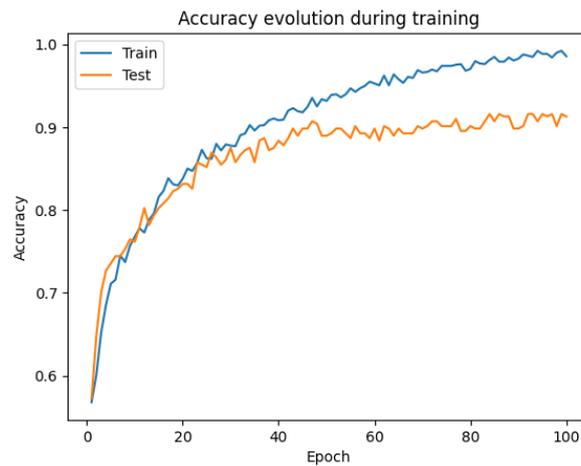
As Figuras 11, 12 e 13 apresentam, respectivamente, a acurácia, o F1-Score e a AUROC dos modelos. As métricas foram coletadas a cada época de treinamento, indicando que todos os modelos convergem para valores próximos (90% de acurácia, 0.85% de F1-Score e 0.95% de AUROC). Além disso, observa-se que essa convergência ocorre rapidamente, nas primeiras 20 a 40 épocas de treinamento, conforme refletido na função de perda, que

Figura 11 – Evolução da acurácia durante o treinamento das redes.



(a) VGG16

(b) VGG19



(c) ResNet50

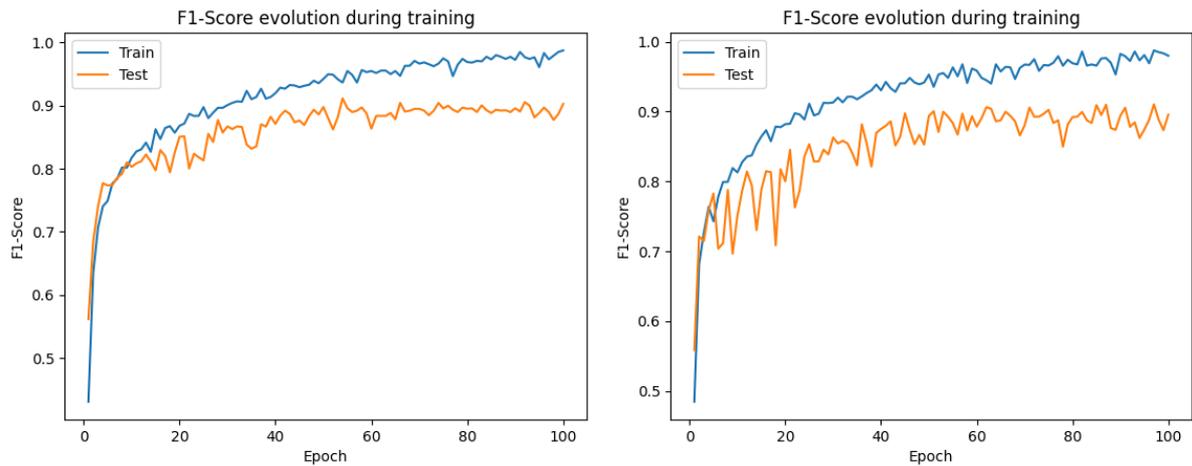
Fonte: Autor.

também diminui rapidamente. Esse comportamento é principalmente atribuído ao uso de arquiteturas pré-treinadas de classificação. Essas arquiteturas já incorporam camadas destinadas à extração de características das imagens, e durante o processo de *transfer learning*, adaptam-se para extrair features específicas do problema em questão.

A Figura 14 compila as versões finais dos modelos e calcula suas curvas ROC. Os dois modelos baseados em VGG alcançaram 0.97 de AUROC, enquanto a ResNet50 atingiu 0.93. Esses modelos são significativamente superiores a uma escolha aleatória, evidenciando a validade dessas técnicas para a detecção de casos de glaucoma em exames de Fotografia de Fundo de Olho.

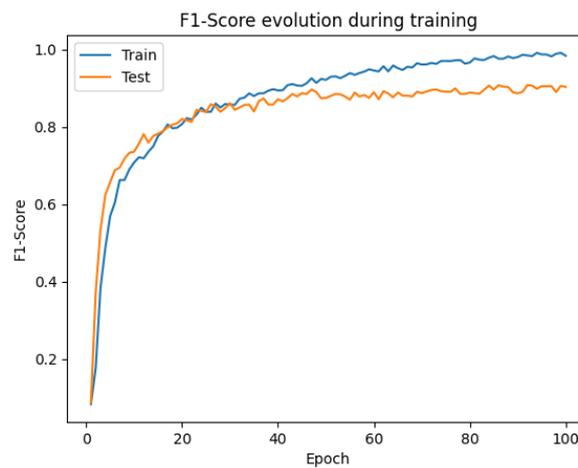
A Tabela 3 apresenta as métricas finais coletadas para cada algoritmo implementado. Todos os algoritmos obtiveram AUROC superiores a 0.9, além de acurácia e F1-Score

Figura 12 – Evolução da F1-Score durante o treinamento das redes.



(a) VGG16

(b) VGG19



(c) ResNet50

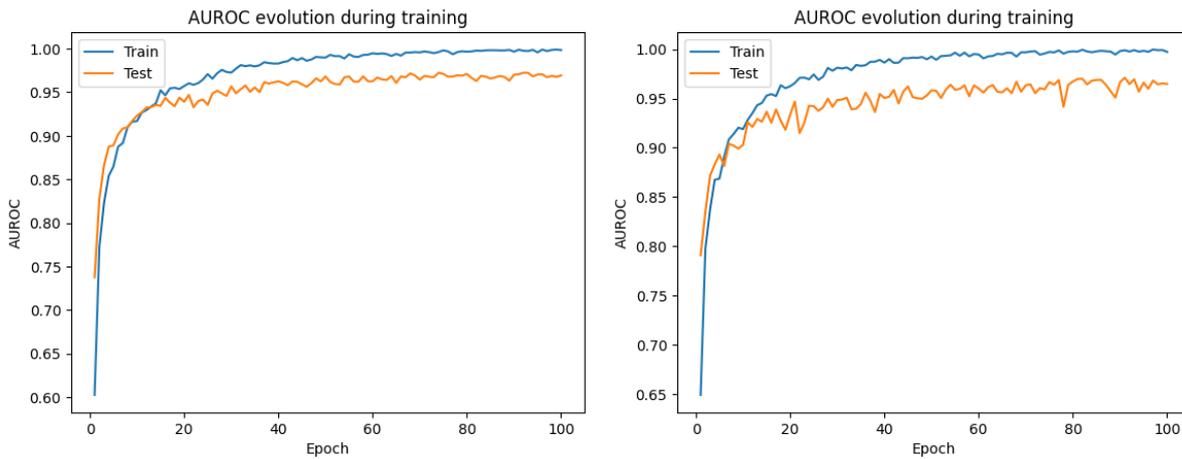
Fonte: Autor.

consideráveis. Esses algoritmos estão disponibilizados no repositório de código do projeto e podem ser utilizados por outros alunos, pesquisadores e professores como uma biblioteca de algoritmos para comparação com novas técnicas e métodos.

Modelo	Acurácia	F1-Score	AUROC
VGG16	<b>0.9127</b>	<b>0.9025</b>	<b>0.9692</b>
VGG19	0.9069	0.8954	0.9647
ResNet50	0.8948	0.8721	0.9338

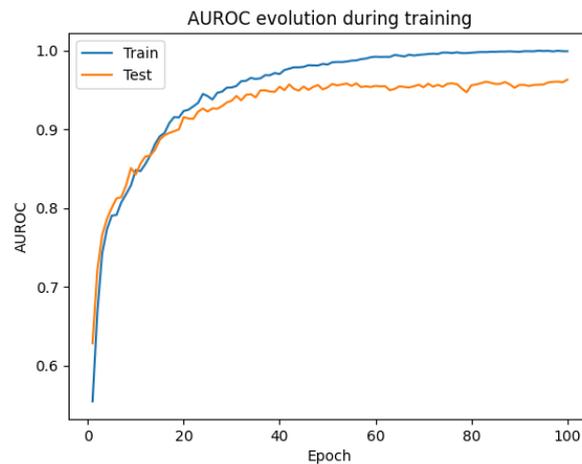
Tabela 3 – Resultados de cada modelo testado.

Figura 13 – Evolução da AUROC durante o treinamento das redes.



(a) VGG16

(b) VGG19



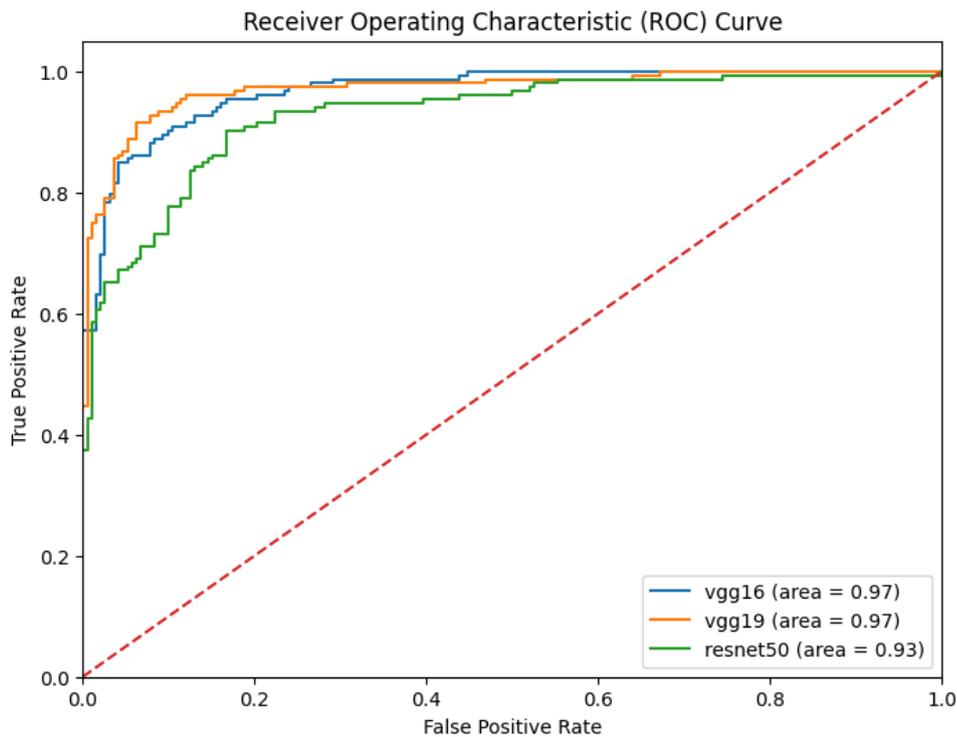
(c) ResNet50

Fonte: Autor.

### 3.8 GANs - Redes Gerativas Adversárias

Num segundo momento, o projeto envolveu a adaptação do código desenvolvido no trabalho (OLIVEIRA, 2021). O objetivo foi utilizar esse código para treinar modelos geradores de novos dados de OCT e, posteriormente, treinar classificadores com base nesses dados. Um desafio primordial ao treinar algoritmos de detecção de glaucoma a partir de exames de OCT reside na escassez de conjuntos de dados que contêm esse tipo de exame, especialmente devido à baixa quantidade de dados em cada dataset. Essa escassez dificulta a tarefa de treinar algoritmos de *Deep Learning*. Portanto, a utilização de modelos generativos pode ajudar ao proporcionar mais dados, criando um dataset mais completo e balanceado, aprimorando o poder de classificação de outros algoritmos.

Figura 14 – Curva ROC para os modelos treinados.



Fonte: Autor.

As Redes Gerativas Adversárias (GANs) são um modelo de aprendizado de máquina proposto por Ian Goodfellow e seus colegas em 2014, conforme apresentado no artigo (GOODFELLOW et al., 2014). A GAN consiste em duas redes neurais, o gerador e o discriminador, que são treinadas simultaneamente por meio de um jogo adversarial. O gerador cria dados sintéticos, enquanto o discriminador avalia a autenticidade desses dados. Essa dinâmica de jogo leva a um aprimoramento contínuo, resultando em dados gerados que se tornam cada vez mais realistas ao longo do treinamento.

A teoria de jogos é uma disciplina matemática que estuda as interações estratégicas entre diferentes "jogadores". Em relação às GANs, o processo de treinamento pode ser interpretado como um jogo entre o gerador e o discriminador. O gerador procura maximizar sua habilidade de enganar o discriminador, enquanto o discriminador procura melhorar sua capacidade de distinguir entre dados reais e sintéticos. Essa interação de estratégias resulta em um equilíbrio dinâmico, conhecido como equilíbrio de Nash, onde o gerador gera dados que são indistinguíveis dos dados reais, e o discriminador é incapaz de diferenciá-los. A teoria de jogos fornece um arcabouço conceitual valioso para entender a dinâmica de aprendizado adversarial nas GANs.

O ACGAN, ou *Generative Adversarial Networks with Auxiliary Classifier*, é uma extensão das GANs que incorpora um classificador adicional no processo de treinamento. Proposto em (ODENA; OLAH; SHLENS, 2017), o ACGAN adiciona uma camada auxiliar

ao discriminador, permitindo que a GAN não apenas gere dados realistas, mas também aprenda a classificar diferentes categorias nos dados gerados.

Essa abordagem aprimora a capacidade da GAN de controlar a geração de dados específicos. O discriminador não apenas determina a autenticidade dos dados, mas também fornece classificações para diferentes categorias. Isso é particularmente útil em tarefas de geração condicional, onde se deseja gerar dados de uma classe específica.

Por exemplo, em um contexto de geração de imagens condicionadas, o ACGAN pode ser treinado para gerar não apenas imagens realistas, mas também para atribuir corretamente rótulos de classe a essas imagens. Isso faz do ACGAN uma escolha poderosa em cenários onde a geração e a classificação estão interligadas, proporcionando maior controle sobre o conteúdo e a qualidade dos dados gerados.

No trabalho de mestrado conduzido por (OLIVEIRA, 2021), a aplicação do ACGAN foi proposta para a geração condicional de mapas de espessura, comumente adquiridos por meio de exames de OCT. No âmbito deste Projeto de Conclusão de Curso, a implementação previamente desenvolvida por (OLIVEIRA, 2021) será avaliada, ajustada conforme necessário e empregada na geração de imagens de mapas de espessura. Essas imagens resultantes poderão, então, ser utilizadas por classificadores no processo de detecção de Glaucoma.

### 3.8.1 Desenvolvimento e Resultados

Nesta segunda etapa, a implementação proposta por (OLIVEIRA, 2021) foi utilizada no treinamento de ACGANs. O propósito é capacitar essas redes gerativas a produzirem mapas de calor com base em OCTs, proporcionando, assim, uma ampliação no conjunto de dados disponíveis para serem utilizados por classificadores. Esse enfoque visa enriquecer a diversidade e a quantidade de informações, aprimorando, conseqüentemente, a capacidade de detecção de glaucoma.

#### 3.8.1.1 Refatoração da base de código para compatibilidade

O primeiro desafio ao utilizar os algoritmos implementados relacionou-se à compatibilidade do código. Originalmente desenvolvido com Python 3.4, versões mais antigas das bibliotecas Keras e Tensorflow, e uma versão de CUDA não suportada pelas GPUs utilizadas, o código enfrentou dificuldades de execução. A necessidade de adaptação surgiu devido a alterações significativas na API, o que tornou essencial a realização de ajustes.

O processo inicial envolveu a identificação dos pontos que requeriam atualização de versão para garantir a compatibilidade com o ambiente de desenvolvimento. Essa etapa foi crucial para assegurar a execução suave do código nas versões mais recentes das bibliotecas e otimizar o desempenho com as GPUs disponíveis.

Ferramenta	Versão Anterior	Versão Atual
CUDA	10.0	12.0
Imagem Docker	cuda:10.0-cudnn7-runtime	tensorflow:2.14.0-gpu-jupyter

Tabela 4 – Versões anteriores e atuais das ferramentas utilizadas.

A Tabela 4 apresenta as ferramentas cujas versões foram atualizadas durante o desenvolvimento do projeto. Inicialmente, o projeto fazia uso de uma imagem Docker fornecida pela NVIDIA com CUDA na versão 10.0, que não estava mais disponível, demandando a busca por uma imagem mais recente. Considerando que as GPUs utilizadas nas máquinas possuíam CUDA na versão 12.0, optou-se por uma imagem compatível com essa versão. A escolha recaiu sobre a imagem fornecida pelo TensorFlow, tensorflow/tensorflow:2.14.0-gpu-jupyter, por ser alinhada com a versão do CUDA e já conter as instalações das ferramentas necessárias, como Keras, TensorFlow e Jupyter Notebooks, entre outras. Essa escolha visou garantir a compatibilidade e a disponibilidade das ferramentas essenciais para o desenvolvimento do projeto.

### 3.8.1.2 Geração de imagens de OCT

Após a atualização das versões e chamadas de API, o próximo passo foi treinar as redes geradoras e discriminadoras. Os dados utilizados foram disponibilizados junto com o código, e incluem 197 imagens saudáveis e 171 imagens de pacientes com glaucoma.

Foram treinados dois tipos diferentes de ACGANs, uma *Vanilla* GAN com o classificador auxiliar, e uma *Wasserstein* GAN com o classificador. A GAN *Wasserstein*, também conhecida como WGAN, é uma variação das GANs convencionais, desenvolvida para abordar algumas limitações e instabilidades observadas em treinamentos de GANs tradicionais. A principal inovação introduzida pelo WGAN está relacionada à função de perda utilizada durante o treinamento.

Diferentemente das GANs convencionais, que empregam a Cross-Entropy (Equações 3.3 e 3.8) como função de perda, as WGANs utilizam a distância de Wasserstein (também conhecida como distância de *Earth Mover*), ilustrada na Equação 3.9, como medida de desempenho. Essa abordagem visa superar problemas como o *mode collapse*, no qual a GAN tradicional pode gerar apenas uma pequena variedade de amostras.

A distância de Wasserstein avalia a discrepância entre as distribuições de probabilidade das amostras reais e geradas. Ao incorporar essa métrica, as WGANs buscam criar uma representação mais suave e contínua do espaço latente, promovendo uma geração mais diversificada e estável de dados. Essa característica torna o treinamento das WGANs mais robusto, mitigando problemas como *vanishing gradient* e *exploding gradient* frequentemente encontrados em GANs convencionais.

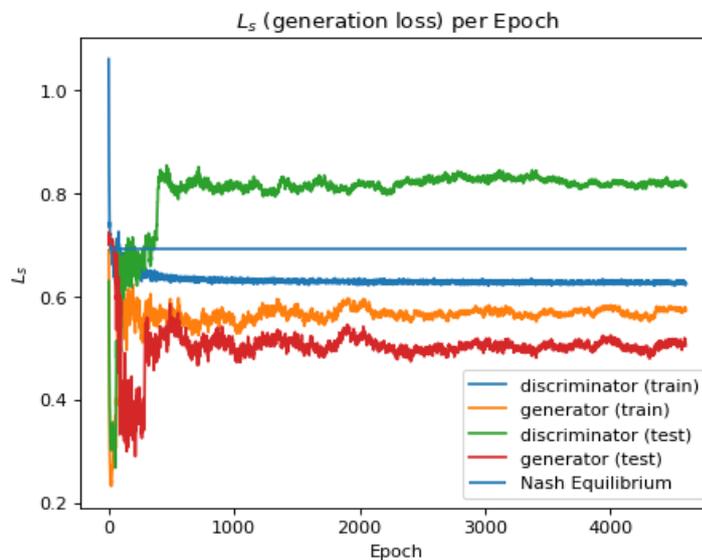
$$L_{\text{GAN}}(G, D) = \mathbb{E}_{x \sim p_{\text{data}}(x)}[\log D(x)] + \mathbb{E}_{z \sim p_z(z)}[\log(1 - D(G(z)))] \quad (3.8)$$

$$L_{\text{WGAN}}(G, D) = \mathbb{E}_{x \sim p_{\text{data}}(x)}[D(x)] - \mathbb{E}_{z \sim p_z(z)}[D(G(z))] \quad (3.9)$$

Os resultados, entretanto, evidenciam os desafios associados ao treinamento de modelos GAN. Na Figura 15, são apresentadas as funções de perda para a rede discriminadora e geradora no contexto da GAN tradicional. Observa-se que, após algumas épocas de treinamento, as perdas alcançam certa estabilidade, contudo, não convergem para o equilíbrio de Nash. Este cenário indica que os algoritmos não foram capazes de atingir um estado de convergência ideal, revelando as dificuldades inerentes ao treinamento desses modelos complexos.

Outras configurações de parâmetros de treinamento e de rede podem se mostrar benéficas para assegurar a convergência das redes, aspecto que deve ser ponderado em projetos futuros que optem por utilizar esse código como base.

Figura 15 – Função de perda para os modelos GAN.

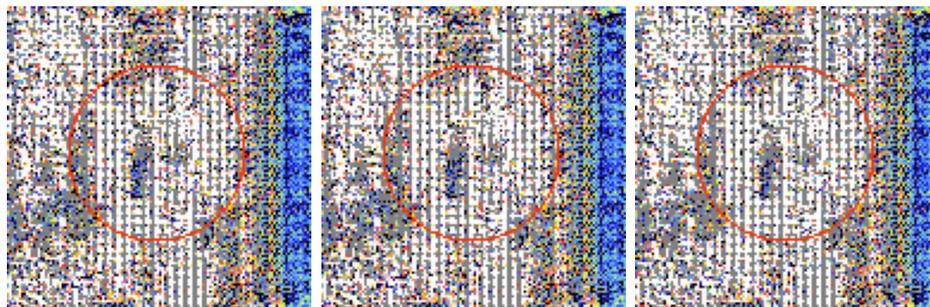


Fonte: Autor.

A Figura 16 exibe três exemplos distintos gerados pela GAN, destacando a notável similaridade entre eles, o que pode indicar a ocorrência de *mode collapse*. Além disso, observa-se que os exemplos são formados principalmente por ruído, sem estrutura, evidenciando a falta de convergência das redes e a incapacidade da rede geradora de aprender de maneira eficaz.

Já a WGAN apresentou um resultado distinto. Ao contrário da GAN, que convergiu, mas não para o equilíbrio, a WGAN teve os modelos divergindo. A Figura 17 ilustra a

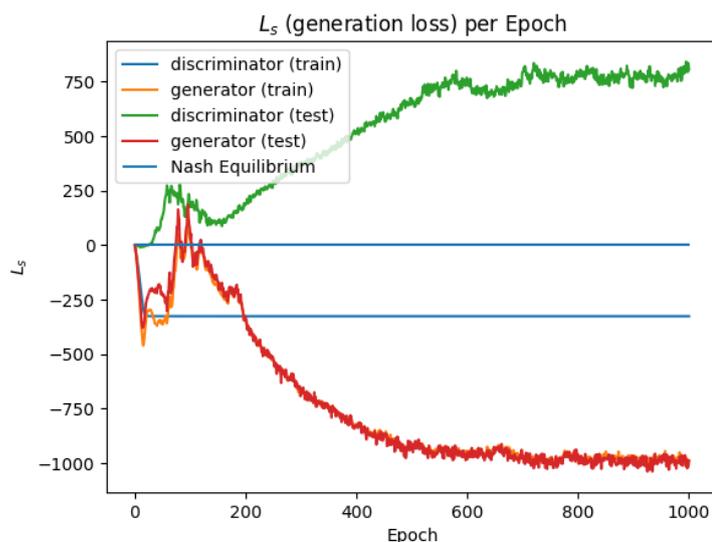
Figura 16 – Imagens geradas pela GAN.



Fonte: Autor.

função de perda das duas redes, evidenciando a divergência em relação ao equilíbrio de Nash. Novamente, esse resultado pode ser atribuído tanto à configuração das redes quanto aos parâmetros, que podem não ser ideais para garantir a convergência desejada.

Figura 17 – Função de perda para os modelos WGAN.



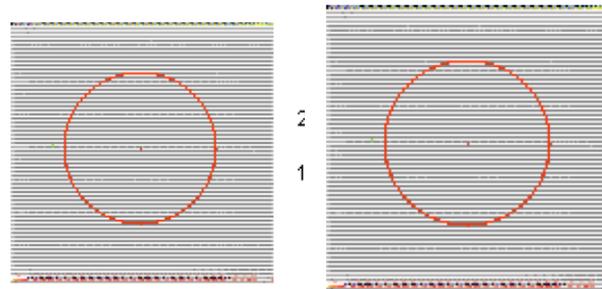
Fonte: Autor.

Os exemplos na Figura 18 também se assemelham a ruído e exibem semelhanças entre si, evidenciando, da mesma forma que no caso da GAN, a falta de convergência e possivelmente *mode collapse*.

### 3.9 Análise dos Resultados

Os algoritmos desenvolvidos têm como propósito servir como base para testes e futuras implementações, constituindo-se como uma biblioteca de algoritmos destinada a pesquisadores na área de detecção de glaucoma. Os três algoritmos de classificação, elaborados para análise de fotografias de fundo de olho, apresentaram resultados satisfatórios,

Figura 18 – Imagens geradas pela WGAN.



Fonte: Autor.

evidenciando uma implementação correta e perspectivas de utilidade no futuro. Essas implementações serão compartilhadas por meio de um repositório, permitindo que usuários futuros reproduzam os resultados e utilizem os algoritmos como ponto de partida para projetos subsequentes.

Embora não tenham sido obtidos resultados satisfatórios na geração de imagens de OCT, a adaptação do código para compatibilidade com versões atuais de bibliotecas e ferramentas representa uma contribuição valiosa. Essa adaptação facilitará a integração do código em futuros projetos na área, reduzindo o tempo de familiarização e potenciais problemas.

Em resumo, o desenvolvimento e os resultados alcançados no projeto estão alinhados com os objetivos estabelecidos. O código será disponibilizado, proporcionando uma base para comparações em futuros estudos.

## 4 Considerações Finais

Este projeto teve como propósito a implementação de métodos validados pela literatura, incluindo algoritmos de segmentação do disco óptico, classificação de fotografias de fundo de olho e a geração de datasets de Tomografia de Coerência Óptica através de Redes Gerativas Adversárias. Apesar da descrição detalhada desses métodos na literatura, suas implementações e modelos treinados não foram disponibilizados publicamente, evidenciando a necessidade de criar uma biblioteca de algoritmos para essas tarefas. Neste projeto destacam-se as implementações bem-sucedidas na segmentação e classificação de fotografias de fundo de olho, que alcançaram métricas satisfatórias de acurácia, F1 e AUROC. Apesar de não terem sido obtidos resultados semelhantes na tarefa de geração de dados, é relevante ressaltar a contribuição do projeto para a compatibilidade e usabilidade da base de código existente, garantindo maior durabilidade à biblioteca e facilitando a base para futuros trabalhos.

### 4.1 Contribuições

As contribuições deste projeto resumem-se a implementação bem-sucedida de algoritmos validados por trabalhos anteriores. Destaca-se a excelência nas implementações dos algoritmos de segmentação e classificação, que resultaram em métricas satisfatórias, evidenciando a correta execução dessas tarefas fundamentais no contexto de detecção de glaucoma. Além disso, a contribuição na refatoração da base de código para modelos GAN e WGAN é notável, uma vez que tornou essas implementações compatíveis com versões atuais de ferramentas utilizadas para *Deep Learning*, proporcionando maior longevidade e usabilidade à biblioteca.

### 4.2 Perspectivas de Continuidade

A partir deste trabalho, outros podem surgir, utilizando-o diretamente em problemas de detecção de glaucoma e comparando os resultados já obtidos, ou adicionando novas implementações à biblioteca. Um dos trabalhos possíveis para o futuro é ajustar as implementações de GAN e WGAN para funcionarem com os conjuntos de dados da equipe e dados públicos.



## Referências

- ABBAS, Q. Glaucoma-deep: Detection of glaucoma eye disease on retinal fundus images using deep learning. *International Journal of Advanced Computer Science and Applications*, v. 8, n. 6, 2017. Citado 3 vezes nas páginas 32, 33 e 36.
- BATISTA, F. J. F. et al. Rim-one dl: A unified retinal image database for assessing glaucoma using deep learning. *Image Analysis and Stereology*, v. 39, n. 3, p. 161–167, Nov. 2020. Disponível em: <<https://www.ias-iss.org/ojs/IAS/article/view/2346>>. Citado 3 vezes nas páginas 18, 32 e 33.
- BOYD, K. *What is glaucoma? Symptoms, Causes, Diagnosis, Treatment*. 2023. Disponível em: <<https://www.aao.org/eye-health/diseases/what-is-glaucoma>>. Citado na página 22.
- BOYD, K.; TURBERT, D. *Eye anatomy: Parts of the eye and how we see*. 2023. Disponível em: <<https://www.aao.org/eye-health/anatomy/parts-of-eye>>. Citado na página 25.
- BUDAI, A. et al. Robust Vessel Segmentation in Fundus Images. *International Journal of Biomedical Imaging*, 2013. Disponível em: <<https://www.hindawi.com/journals/ijbi/2013/154860/>>. Citado 2 vezes nas páginas 32 e 33.
- BUITINCK, L. et al. API design for machine learning software: experiences from the scikit-learn project. In: *ECML PKDD Workshop: Languages for Data Mining and Machine Learning*. [S.l.: s.n.], 2013. p. 108–122. Citado na página 38.
- CHEEMA, A.; AREF, A. A.; MOORE, D. B. *Spectral domain optical coherence tomography in glaucoma*. 2022. Disponível em: <[https://eyewiki.aao.org/Spectral\\_Domain\\_Optical\\_Coherence\\_Tomography\\_in\\_Glaucoma](https://eyewiki.aao.org/Spectral_Domain_Optical_Coherence_Tomography_in_Glaucoma)>. Citado na página 30.
- Conselho Brasileiro de Oftalmologia. *Série Oftalmologia Brasileira*. [s.n.]. v. 9. Disponível em: <[https://issuu.com/computadorseguro/docs/09\\_glaucoma](https://issuu.com/computadorseguro/docs/09_glaucoma)>. Citado 2 vezes nas páginas 23 e 25.
- DIAZ-PINTO, A. et al. CNNs for Automatic Glaucoma Assessment using Fundus Images: An Extensive Validation. 3 2019. Disponível em: <[https://figshare.com/articles/dataset/CNNs\\_for\\_Automatic\\_Glaucoma\\_Assessment\\_using\\_Fundus\\_Images\\_An\\_Extensive\\_Validation/7613135](https://figshare.com/articles/dataset/CNNs_for_Automatic_Glaucoma_Assessment_using_Fundus_Images_An_Extensive_Validation/7613135)>. Citado 3 vezes nas páginas 17, 32 e 33.
- FELDMAN, B. H. et al. *Optic nerve and retinal nerve fiber imaging*. 2022. Disponível em: <[https://eyewiki.aao.org/Optic\\_Nerve\\_and\\_Retinal\\_Nerve\\_Fiber\\_Imaging](https://eyewiki.aao.org/Optic_Nerve_and_Retinal_Nerve_Fiber_Imaging)>. Citado na página 29.
- GAVA, F. D. et al. Cegueira silenciosa: Revisão narrativa e estudo epidemiológico do glaucoma no brasil entre 2017 e 2022. *Brazilian Journal of Health Review*, v. 5, n. 5, p. 19945–19955, 2022. Citado na página 22.
- GOODFELLOW, I. J. et al. *Generative Adversarial Networks*. 2014. Citado na página 45.

HE, K. et al. *Deep Residual Learning for Image Recognition*. 2015. Citado 5 vezes nas páginas 17, 31, 32, 33 e 41.

HEALTH, C. E. *Normal optic disc and glaucomatous optic nerve heads of two patients with different severities of glaucoma*. 2013. Disponível em: <<https://www.flickr.com/photos/communityeyehealth/8438913314>>. Citado na página 30.

HUNTER, J. D. Matplotlib: A 2d graphics environment. *Computing in science & engineering*, IEEE, v. 9, n. 3, p. 90–95, 2007. Citado na página 38.

ISLAM, M. T. et al. Deep learning-based glaucoma detection with cropped optic cup and disc and blood vessel segmentation. *IEEE Access*, v. 10, p. 2828–2841, 2022. Citado na página 18.

JINDAL, A. P. et al. *Primary open-angle glaucoma*. 2023. Disponível em: <[https://eyewiki.aao.org/Primary\\_Open-Angle\\_Glaucoma](https://eyewiki.aao.org/Primary_Open-Angle_Glaucoma)>. Citado na página 27.

KASS, M. A. et al. The ocular hypertension treatment study: a randomized trial determines that topical ocular hypotensive medication delays or prevents the onset of primary open-angle glaucoma. *Arch Ophthalmol*, United States, v. 120, n. 6, p. 701–13; discussion 829–30, jun. 2002. Citado na página 23.

KHAZAENI, B.; KHAZAENI, L. *Acute closed angle glaucoma*. [S.l.]: StatPearls Publishing, 2023. Citado na página 27.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: PEREIRA, F. et al. (Ed.). *Advances in Neural Information Processing Systems*. Curran Associates, Inc., 2012. v. 25. Disponível em: <[https://proceedings.neurips.cc/paper\\_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf](https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf)>. Citado na página 17.

LONG, J.; SHELHAMER, E.; DARRELL, T. *Fully Convolutional Networks for Semantic Segmentation*. 2015. Citado na página 33.

MAHABADI, N.; FORIS, L. A.; TRIPATHY, K. *Open Angle Glaucoma*. [S.l.]: StatPearls Publishing, 2022. Citado na página 27.

National Eye Institut. U.S. Department of Health and Human Services, 2021. Disponível em: <<https://www.nei.nih.gov/learn-about-eye-health/eye-conditions-and-diseases/glaucoma/types-glaucoma>>. Citado 2 vezes nas páginas 27 e 28.

ODENA, A.; OLAH, C.; SHLENS, J. *Conditional Image Synthesis With Auxiliary Classifier GANs*. 2017. Citado na página 45.

OLIVEIRA, G. O. D. *Geração de mapas de espessuras sintéticos por meio de redes generativas adversárias para o treinamento de redes neurais profundas para auxílio ao diagnóstico de glaucoma*. Dissertação (Mestrado) — Escola Politécnica da Universidade de São Paulo, 2021. Citado 5 vezes nas páginas 17, 44, 46, 59 e 60.

OSAGUONA, V. B. Differential diagnoses of the pale/white/atrophic disc. *Community Eye Health*, England, v. 29, n. 96, p. 71–74, 2016. Citado na página 29.

- PASZKE, A. et al. Pytorch: An imperative style, high-performance deep learning library. In: *Advances in Neural Information Processing Systems 32*. Curran Associates, Inc., 2019. p. 8024–8035. Disponível em: <<http://papers.neurips.cc/paper/9015-pytorch-an-imperative-style-high-performance-deep-learning-library.pdf>>. Citado na página 38.
- PEREZ, L.; WANG, J. *The Effectiveness of Data Augmentation in Image Classification using Deep Learning*. 2017. Citado na página 34.
- RHCASTILHOS. *Diagrama esquemático de um olho humano*. 2013. Disponível em: <[https://commons.wikimedia.org/wiki/File:Schematic\\_diagram\\_of\\_the\\_human\\_eye\\_horizontal\\_pt.svg](https://commons.wikimedia.org/wiki/File:Schematic_diagram_of_the_human_eye_horizontal_pt.svg)>. Citado na página 24.
- ROSSUM, G. V.; DRAKE, F. L. *Python 3 Reference Manual*. Scotts Valley, CA: CreateSpace, 2009. ISBN 1441412697. Citado na página 38.
- SALIM, S. et al. *IOP and Tonometry*. 2022. Disponível em: <[https://eyewiki.aao.org/IOP\\_and\\_Tonometry](https://eyewiki.aao.org/IOP_and_Tonometry)>. Citado na página 29.
- SIMONYAN, K.; ZISSERMAN, A. *Very Deep Convolutional Networks for Large-Scale Image Recognition*. 2015. Citado 4 vezes nas páginas 17, 31, 32 e 41.
- SIVASWAMY, J. et al. Drishti-gs: Retinal image dataset for optic nerve head(onh) segmentation. In: *2014 IEEE 11th International Symposium on Biomedical Imaging (ISBI)*. [S.l.: s.n.], 2014. p. 53–56. Citado 3 vezes nas páginas 18, 32 e 33.
- STAMPER, R. L. A history of intraocular pressure and its measurement. *Optometry and Vision Science*, v. 88, n. 1, 2011. ISSN 1538-9235. Disponível em: <[https://journals.lww.com/optvissci/fulltext/2011/01000/a\\_history\\_of\\_intraocular\\_pressure\\_and\\_its.6.aspx](https://journals.lww.com/optvissci/fulltext/2011/01000/a_history_of_intraocular_pressure_and_its.6.aspx)>. Citado na página 29.
- THAM, Y.-C. et al. Global prevalence of glaucoma and projections of glaucoma burden through 2040: a systematic review and meta-analysis. *Ophthalmology*, United States, v. 121, n. 11, p. 2081–2090, jun. 2014. Citado na página 21.
- TSEKICHUN. *Data Augmentation of rock images including flip and random crop*. 2021. Disponível em: <[https://commons.m.wikimedia.org/wiki/File:Data\\_Augmentation\\_of\\_rock\\_images.jpg](https://commons.m.wikimedia.org/wiki/File:Data_Augmentation_of_rock_images.jpg)>. Citado na página 34.
- VARMA, R. et al. An assessment of the health and economic burdens of glaucoma. *Am J Ophthalmol*, United States, v. 152, n. 4, p. 515–522, out. 2011. Citado na página 23.
- WELLS, J.; GRASSMEYER, J.; AWH, C. *Basic histology of the eye and accessory structures*. Disponível em: <[https://eyewiki.aao.org/Basic\\_Histology\\_of\\_the\\_Eye\\_and\\_Accessory\\_Structures](https://eyewiki.aao.org/Basic_Histology_of_the_Eye_and_Accessory_Structures)>. Citado na página 24.
- XU, P. et al. Optic disc detection via deep learning in fundus images. In: *FIFI/OMIA@MICCAI*. [s.n.], 2017. Disponível em: <<https://api.semanticscholar.org/CorpusID:42308772>>. Citado na página 32.
- ZHANG, Z. et al. Origa-light: An online retinal fundus image database for glaucoma analysis and research. *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology*, 2010. Citado 2 vezes nas páginas 33 e 38.

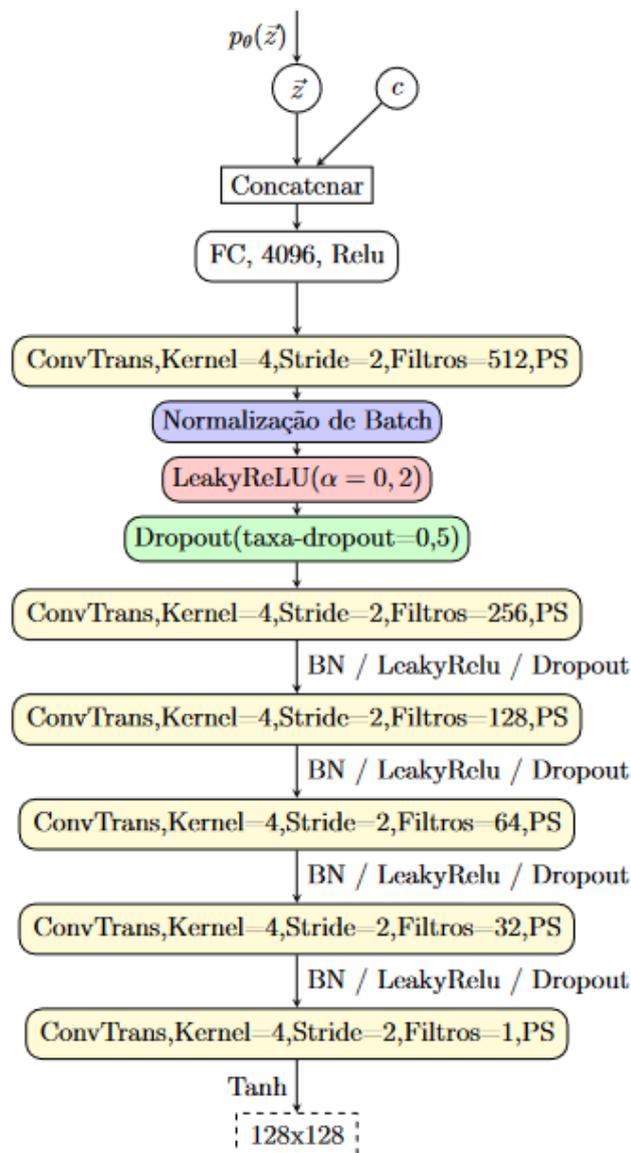


# Apêndices



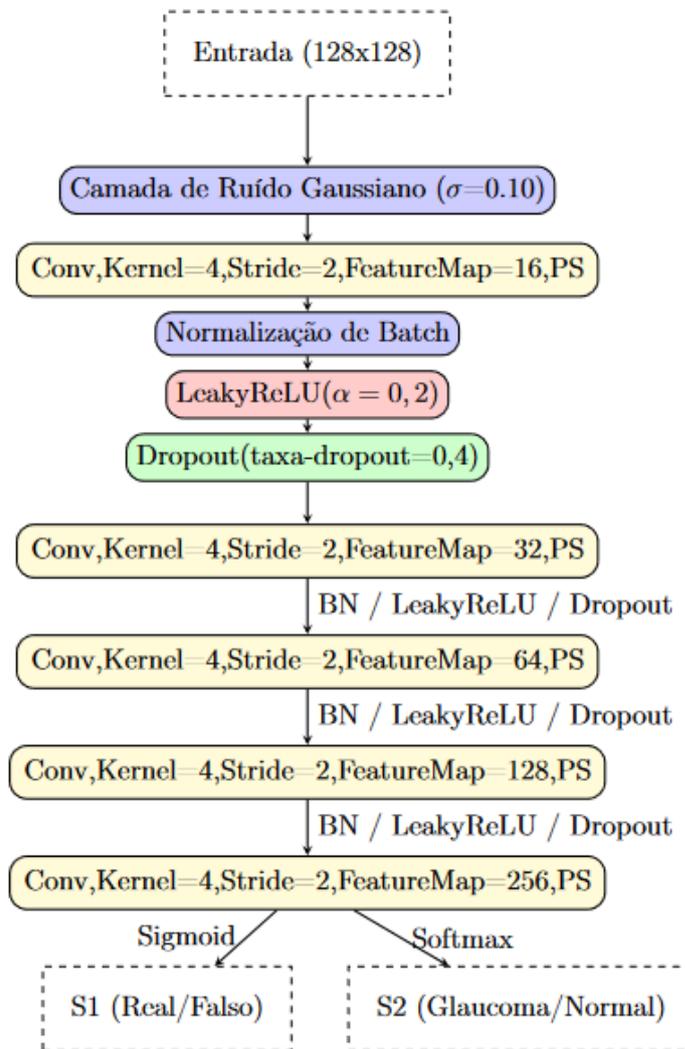
# APÊNDICE A – Arquiteturas de Redes Neurais utilizadas para as redes GAN e WGAN

Figura 19 – Arquitetura da Rede Geradora.



Fonte: (OLIVEIRA, 2021)

Figura 20 – Arquitetura da Rede Discriminadora.



Fonte: (OLIVEIRA, 2021)