

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA  
FACULDADE DE GESTÃO E NEGÓCIOS  
GRADUAÇÃO EM GESTÃO DA INFORMAÇÃO**

**GUILHERME DE SOUZA LIMA**

**Diagnóstico Oftalmológico Inteligente: aplicação de machine learning na  
detecção precoce do glaucoma**

**ORIENTADOR: PROF. DR. JOSÉ EDUARDO FERREIRA LOPES**

**UBERLÂNDIA – MG**

**2025**

**GUILHERME DE SOUZA LIMA**

**Diagnóstico Oftalmológico Inteligente: aplicação de machine learning na  
detecção precoce do glaucoma**

Monografia apresentada ao Curso de Graduação em Gestão da Informação, da Universidade Federal de Uberlândia, como exigência parcial para a obtenção do título de Bacharel.

Orientador: Prof. Dr. José Eduardo Ferreira Lopes

**UBERLÂNDIA – MG**

**2025**

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU  
com dados informados pelo(a) próprio(a) autor(a).

L732  
2025

Lima, Guilherme de Souza, 2000-  
Diagnóstico Oftalmológico Inteligente: aplicação de machine  
learning na detecção precoce do glaucoma [recurso eletrônico] /  
Guilherme de Souza Lima. - 2025.

Orientador: José Eduardo Ferreira Lopes.

Trabalho de Conclusão de Curso (graduação) - Universidade  
Federal de Uberlândia, Graduação em Gestão da Informação.

Modo de acesso: Internet.

Inclui bibliografia.

Inclui ilustrações.

1. Gestão do conhecimento. I. Lopes, José Eduardo Ferreira,  
1971-, (Orient.). II. Universidade Federal de Uberlândia.  
Graduação em Gestão da Informação. III. Título.

CDU: 658.012.22

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091

Nelson Marcos Ferreira - CRB6/3074

## RESUMO

Objetivou-se com este relato tecnológico apresentar um projeto-base de a aplicação de aprendizado de máquina (*machine learning* – ML) no diagnóstico de doenças oftalmológicas, com foco na detecção precoce do glaucoma. A situação problema observada foi a ausência de um sistema automatizado de triagem em uma clínica oftalmológica de porte médio, que atua com base em um banco de dados centralizado, porém ainda sem uso estratégico da informação para apoio à decisão médica. Como solução, propôs-se o desenvolvimento de um módulo computacional capaz de analisar exames de tomografia de coerência óptica (OCT) e identificar padrões compatíveis com alterações glaucomatosas. A base do sistema de aprendizado de máquina apresentado seria uma ferramenta de apoio à triagem inicial, auxiliando na priorização dos atendimentos, na padronização das análises e no melhor aproveitamento do banco de dados clínico interno existente. O projeto apresentado deseja alcançar resultados como a redução do tempo de resposta entre o exame e a conduta médica, o aumento da taxa de diagnóstico precoce, a otimização do tempo da equipe médica e a melhoria da gestão das informações clínicas, com potencial de expansão para outras patologias do contextos institucionais.

**Palavras-chave:** Diagnóstico precoce; Glaucoma; *Machine learning*; Saúde digital; Tomografia de coerência óptica.

## SUMÁRIO

<b>1 INTRODUÇÃO.....</b>	<b>5</b>
<b>2 FUNDAMENTAÇÃO TEÓRICA.....</b>	<b>9</b>
2.1 Glaucoma Aspectos Clínicos e Epidemiológicos.....	9
2.1.1 Fisiopatologia do Glaucoma.....	10
2.1.2 Tipos de Glaucoma.....	11
2.2 Exames Oftalmológicos e Fontes de Dados.....	14
2.2.1 Campo Visual (Perimetria).....	14
2.2.2 Tomografia de Coerência Óptica (OCT).....	16
2.2.3 Retinografia (Fundos de Olho).....	16
2.2.4 Parâmetros Clínicos.....	17
2.3 Machine Learning.....	19
2.3.1 Conceito Geral.....	19
2.3.2 Algoritmos Usados.....	20
2.3.3 Aplicações na Detecção Precoce do Glaucoma.....	21
2.3.4 Exemplo de estudo acadêmico.....	21
2.3.5 Aplicações de Machine Learning na Medicina.....	22
2.4 Trabalhos Relacionados.....	22
2.4.1 Redes Neurais Convolucionais (CNNs) em retinografia.....	22
2.4.2 Random Forest e Support Vector Machine (SVM) com dados clínicos.....	23
2.4.3 Integração de OCT e perimetria com ML.....	23
2.4.4 Triagem populacional automatizada.....	24
<b>3 CONTEXTO INVESTIGADO E SITUAÇÃO PROBLEMA.....</b>	<b>24</b>
<b>4 INTERVENÇÃO ADOTADA.....</b>	<b>25</b>
4.1 Etapas previstas da intervenção.....	26
4.1.1 Coleta e organização dos dados clínicos e de imagem.....	26
4.1.2 Pré-processamento das imagens.....	32
4.1.3 Extração de características.....	33
4.1.4 Treinamento do modelo de aprendizado de máquina.....	33
4.1.5 Validação e testes em ambiente controlado.....	34
4.1.6 Criação de um painel inteligente de triagem.....	35
4.1.7 Integração ao sistema clínico da instituição.....	35
4.1.8 Treinamento da equipe e acompanhamento contínuo.....	36
<b>5 RESULTADOS ALCANÇADOS (OU ESPERADOS).....</b>	<b>36</b>
5.1 Melhoria na triagem e tomada de decisão.....	37
5.2 Diagnóstico mais precoce e assertivo.....	37
5.3 Redução da variabilidade entre especialistas.....	37
5.4 Uso inteligente do banco de dados clínicos.....	37
5.5 Otimização do tempo da equipe médica.....	38
5.6 Melhoria da experiência do paciente.....	38
5.7 Potencial de expansão.....	38
<b>6 CONSIDERAÇÕES FINAIS.....</b>	<b>38</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>41</b>

## 1 INTRODUÇÃO

Segundo Thacharodi et al. (2024), a revolução tecnológica tem impactado significativamente a área da saúde, especialmente na estruturação, análise e aplicação de dados clínicos, contribuindo para o aprimoramento do diagnóstico e da concepção de tratamentos. Entre as novidades que se destacam, o aprendizado de máquina (*machine learning* – ML), aparece como uma ferramenta. Com capacidade de processar grandes volumes de dados, como aqueles gerados em ambientes de Big Data em alta velocidade e em formatos diversos, essa tecnologia emprega ferramentas avançadas para tratar e analisar informações Taurion(2013). Identificar padrões de forma autônoma e apoiar decisões médicas de maneira mais rápida e precisa, além de otimizar a distribuição de recursos (Bagam, 2020).

O conceito de aprendizado de máquina, iniciado no final da década de 1940 com os primeiros modelos de redes neurais, ganhou novo impulso com os avanços no poder computacional, o desenvolvimento de algoritmos mais sofisticados como a aprendizagem profunda (*deep learning*) e as redes generativas adversariais (*generative adversarial networks* – GANs) e o crescimento exponencial da disponibilidade de dados. As GANs são um tipo de rede neural composta por dois modelos que competem entre si um gerador e um discriminador permitindo a criação de dados sintéticos altamente realistas, como imagens e vídeos, a partir de padrões aprendidos nos dados de treinamento. Esse avanço tem sido explorado em diferentes estudos, como a revisão histórica de Ekundayo et al. (2025) sobre *deep learning* e a análise de Avanzo (2024) no contexto de imagens médicas. As características e o desempenho das GANs também são detalhados por Gui et al. (2020). De acordo com a definição clássica de Mitchell (1997), um sistema pode ser considerado capaz de aprender quando, ao receber mais dados e feedback, melhora seu desempenho em uma tarefa específica.

Essa ideia tem se concretizado em várias áreas da medicina, onde o *machine learning* vem sendo utilizado com sucesso para resolver desafios diagnósticos e preditivos. Segundo Braga et al., (2019), essa abordagem proporciona maior precisão e confiabilidade aos diagnósticos e contribuindo para o avanço da medicina de precisão. Na dermatologia, sistemas inteligentes auxiliam na triagem de lesões cutâneas suspeitas de câncer de pele, melhorando a acurácia do diagnóstico em fases iniciais (Ting et al., 2019). Na cardiologia, de acordo com Shahriari et al. (2025), o uso dessas tecnologias tem permitido a análise de eletrocardiogramas e a

previsão de eventos cardíacos com mais rapidez e confiabilidade. Esse avanço tecnológico é impulsionado pelo aumento do poder computacional, melhoria dos algoritmos e acesso a grandes volumes de dados médicos (Tonti *et al.* 2024).

Por sua vez, na oftalmologia, o impacto do *machine learning* é especialmente notável em detecção de doenças como o glaucoma, também conhecido como neuropatia óptica glaucomatosa (*glaucomatous optic neuropathy* – GON), por ser uma doença crônica e progressiva que compromete o nervo óptico de forma silenciosa e muitas vezes irreversível, cujo sintomas geralmente só se manifestam em estágios avançados conforme (Lee *et al.*, 2021). O uso de algoritmos capazes de identificar padrões sutis em exames como OCT, retinografias e campos visuais tem contribuído para diagnósticos mais precoces, personalizados e assertivos, especialmente em regiões com escassez de especialistas (Tonti *et al.*, 2024).

Por isso, o diagnóstico precoce é decisivo para evitar danos irreversíveis à visão e manter a qualidade de vida do paciente. Porém, o diagnóstico é complexo, exigindo uma análise detalhada de vários exames complementares como a tomografia de coerência óptica (*optical coherence tomography* – OCT), o campo visual (*perimetria*), as medidas da pressão intraocular (PIO) e a avaliação clínica da papila óptica conforme descrito pela Glaucoma Patients Association (2024).

A complexidade do diagnóstico do glaucoma está na necessidade de interpretar uma variedade de exames complementares, o que exige não só experiência e conhecimento profundo, mas também uma sensibilidade clínica do profissional para identificar pequenas alterações de acordo publicado por Malheiros *et al.* (2024). Além disso, as variações anatômicas entre os pacientes, a flutuação da pressão intraocular e a sutileza das alterações nos estágios iniciais da doença que muitas vezes são imperceptíveis sem a ajuda de tecnologia avançada tornam o diagnóstico ainda mais difícil, aumentando o risco de não detectar, de um tratamento tardio ou até de um diagnóstico falso-positivo, com consequências devastadoras para visão do paciente e para o sistema de saúde.

Além disso, a detecção precoce do glaucoma é desafiadora devido à ausência de sintomas iniciais, às variações anatômicas entre os pacientes, às flutuações da pressão intraocular e às alterações sutis nos estágios iniciais. Esses fatores, aliados à falta de tecnologias avançadas, como a tomografia de coerência óptica (OCT) e a perimetria automatizada, aumentam o risco de diagnóstico tardio ou incorreto, podendo resultar em não detecção, tratamento inadequado ou até falsos positivos,

com consequências potencialmente devastadoras para a visão do paciente conforme Alcântara, E. P. de, (2024).

É nesse cenário desafiador que os algoritmos de aprendizado de máquina se tornam ferramentas de suporte ao diagnóstico como referenciado por Da Silva (2013). Técnicas avançadas, como as redes neurais convolucionais (*convolutional neural networks* – CNNs), as árvores de decisão (*decision trees*), e as máquinas de vetor de suporte (*support vector machines* – SVMs), têm sido utilizadas com sucesso na análise de imagens de fundo de olho (retinografias), curvas de pressão intraocular, campos visuais e exames de OCT baseado em Maetschke *et al.* (2019).

Segundo Zhou *et al.* (2016), modelos baseados em *deep learning* são capazes de extrair características profundas que permitem a localização discriminativa de padrões em imagens médicas, como os associados à perda de fibras nervosas ou alterações no disco óptico em casos de glaucoma.

Além do diagnóstico, a aplicação do *machine learning* na oftalmologia tem se mostrado eficaz também na previsão da progressão da doença. Modelos preditivos baseados em *deep learning* vêm sendo desenvolvidos com alta precisão, como demonstrado por Hussain *et al.* (2023), que propuseram uma abordagem multimodal utilizando dados clínicos e exames complementares para prever a evolução do glaucoma. Isso permite que os profissionais de saúde ajustem os planos de tratamento de forma personalizada e proativa, atrasando ou até interrompendo a progressão da perda visual.

A crescente quantidade de pesquisas científicas confirma a eficácia do *machine learning* na área oftalmológica, demonstrando que sua precisão em determinadas tarefas de diagnóstico pode ser comparável e, em alguns casos, até superior à de especialistas humanos. Estudos relevantes, como o de Asaoka *et al.* (2016), evidenciam a alta acurácia de redes neurais convolucionais (*convolutional neural networks* – CNNs) na detecção de glaucoma por meio de imagens de fundo de olho. Já Li *et al.* (2020) investigaram a aplicação de algoritmos de aprendizagem profunda (*deep learning*) na previsão da progressão do campo visual, demonstrando resultados promissores. Essas evidências reforçam o potencial dessas ferramentas em aumentar a sensibilidade e a especificidade da detecção do glaucoma inclusive em suas fases iniciais, quando as alterações ainda não são perceptíveis clinicamente e em oferecer suporte qualificado à tomada de decisão dos profissionais de saúde.



Considerando todos esses fatores, as tecnologias baseadas em *machine learning* surgem como uma alternativa promissora e um complemento valioso para a prática clínica. Zhang *et al.* (2025) demonstram em revisão abrangente que esses modelos conseguem identificar padrões precoces e prognosticar progressão do glaucoma, o que possibilita triagem automatizada, otimização diagnóstica e maior qualidade no atendimento, especialmente em regiões com poucos especialistas.

Além disso, a integração dessa abordagem inovadora contribui para o aprimoramento da gestão da informação em saúde, otimizando a organização e o uso dos dados clínicos para tomadas de decisão mais rápidas e fundamentadas em evidências. Sistemas de suporte à decisão clínica (CDSS) têm se mostrado eficazes nesse contexto, ao incorporar o uso de *machine learning* em clínicas oftalmológicas para apoiar o diagnóstico, o monitoramento e a escolha de tratamentos para o glaucoma Shahriari; Darvish, (2024). A implementação de técnicas de *machine learning* em plataformas como o sistema GlaucomAI tem favorecido a interoperabilidade entre sistemas hospitalares e a análise colaborativa de dados, promovendo triagens automatizadas mais eficientes Świerczyński *et al.* (2025). De acordo com Savastano *et al.* (2025), essas tecnologias ainda ajudam a padronizar a avaliação de exames, reduzir erros humanos e ampliar o acesso à saúde ocular de qualidade, um avanço particularmente significativo em regiões com escassez de especialistas.

Dessa forma, este relato tecnológico visa apresentar os benefícios de um projeto-base de aplicação de aprendizado de máquina no diagnóstico de doenças oftalmológicas, com ênfase na detecção precoce do glaucoma.

## **2 FUNDAMENTAÇÃO TEÓRICA**

### **2.1 Glaucoma Aspectos Clínicos e Epidemiológicos**

O glaucoma é uma neuropatia óptica progressiva caracterizada pela degeneração das fibras nervosas da retina e alterações do disco óptico Susanna Jr., (2020). A consequência direta é a perda gradual do campo visual, muitas vezes sem sintomas iniciais, sendo conhecido como o “ladão silencioso da visão”. Na figura 1 é apresentado os estágios da perda do campo de visão contendo primeiramente a visão normal e em seguida três estágios do glaucoma, evidenciando a perda progressiva do campo de visão PHELCOM (2023).

Figura 1 – Estágios da perda do campo de visão devido ao glaucoma



Fonte: PHELCOM (2023).

### 2.1.1 Fisiopatologia do Glaucoma

O dano ao nervo óptico no glaucoma ocorre, principalmente, devido ao aumento da pressão intraocular (PIO). Esse aumento acontece quando o humor aquoso fluido transparente e incolor produzido pelos processos ciliares não é drenado de maneira eficiente, acumulando-se nas câmaras anterior e posterior do olho. Essa falha na drenagem leva à elevação da pressão interna, que, por sua vez, comprime as fibras nervosas do nervo óptico, gerando danos progressivos e, muitas vezes, irreversíveis à visão Statpearls, (2023).


Alterações vasculares, como crescimento de vasos anormais ou redução sutil de densidade vascular retiniana, autorregulação prejudicada do fluxo sanguíneo e micro-oclusões, têm sido associadas a afinamento da camada de fibras nervosas da retina (RNFL) e depósito de dano ao nervo óptico, mesmo em casos de pressão

intraocular normal. Wang *et al.* (2023) demonstraram que a densidade vascular peripapilar reduzida correlaciona-se com perda de RNFL e piora do campo visual, reforçando que essas alterações vasculares são componentes críticos da fisiopatologia do glaucoma inicial. O dano é geralmente irreversível, e a progressão lenta dificulta a percepção precoce pelo paciente.

### 2.1.2 Tipos de Glaucoma

O glaucoma de Ângulo Aberto (Crônico) é o tipo mais prevalente, responsável pela maioria dos casos. Ocorre devido ao mau funcionamento gradual do trabéculo, a rede de drenagem natural do olho, impedindo o escoamento adequado do humor aquoso, o líquido que preenche a parte anterior do olho. Isso resulta em aumento lento e progressivo da pressão intraocular (PIO) Sharts-Hopko; Glynn-Milley (2009). A doença é assintomática nas fases iniciais, tornando a perda de visão periférica quase imperceptível até que esteja em estágio avançado. Por isso, o glaucoma de ângulo aberto é frequentemente chamado de “doença silenciosa”, e triagens regulares e exames oftalmológicos são essenciais para diagnóstico precoce por Fernandes *et al.* (2019). Na figura 2 é exibido uma imagem detalhando partes do olho humano, identificando o fluxo correto do humor aquoso, no qual quando esse fluxo não responde corretamente, acarreta no aumento da pressão intraocular IOC (2023).


Figura 2 – Fluxo do humor aquoso.



Fonte: IOC (2023).

O Glaucoma de Ângulo Fechado (Agudo) é menos comum, mas clinicamente mais grave. Ocorre quando a íris bloqueia abruptamente o ângulo de drenagem, impedindo o escoamento do humor aquoso. Isso provoca aumento súbito e significativo da PIO, caracterizando uma emergência oftalmológica. Os sintomas incluem dor ocular intensa, visão turva, percepção de halos ao redor de luzes, vermelhidão ocular, dor de cabeça e náuseas ou vômitos. A intervenção médica imediata é crucial para evitar a perda permanente da visão Pohl; Tarnutzer (2018). Na figura 3, é mostrado uma imagem que demonstra o glaucoma agudo na esquerda mostra um ângulo aberto normal, enquanto a central exibe uma drenagem normal do humor aquoso. Já a figura à direita ilustra o bloqueio pupilar e o fechamento angular, causados pelo contato entre a íris e a malha trabecular Glaucoma Patients Association (2018).

Figura 3 – Processo para formação do glaucoma de ângulo fechado.



Fonte: Glaucoma Patients Association (2018).

O Glaucoma Congênito é uma forma rara presente desde o nascimento ou primeiros anos de vida, causada por desenvolvimento anormal do sistema de drenagem ocular Reis *et al.* (2024). Crianças afetadas podem apresentar olhos anormalmente grandes (búftalmia), fotofobia e lacrimejamento excessivo. O diagnóstico precoce em lactentes e crianças é vital para a preservação da visão, na figura 4 é exposto um olho de uma criança com glaucoma congênito Glaucoma Patients Association (2018).

Figura 4 – Olhos com glaucoma congênito.



Fonte: Glaucoma Patients Association (2018).

O Glaucoma Secundário desenvolve-se como complicação de outras condições médicas ou oculares, como traumas, inflamações intra oculares (uveíte), uso prolongado de medicamentos (ex.: corticosteroides) ou doenças preexistentes como catarata avançada, retinopatia diabética ou oclusões vasculares da retina Witmer (1986). O tratamento envolve manejo da condição subjacente e controle da PIO.

Glaucoma de Pressão Normal (ou de Baixa Pressão): Caracteriza-se pelo dano ao nervo óptico e perda de campo visual, mesmo com PIO dentro dos limites considerados normais fatores como fluxo sanguíneo insuficiente para o nervo óptico ou sensibilidade elevada do nervo à pressão normal podem estar envolvidos o diagnóstico requer avaliação cuidadosa para descartar outras neuropatias ópticas Tavares; Mello, (2005).

De acordo com o Ministério da Saúde (2025), o glaucoma está entre as principais doenças oculares que podem levar à perda de visão se não forem diagnosticadas e tratadas precocemente. A prevalência aumenta com a idade, afetando milhões de pessoas globalmente. Em muitos países, é a segunda principal causa de cegueira, perdendo apenas para a catarata que, ao contrário do glaucoma, pode ser tratada cirurgicamente para restaurar a visão.

Embora não haja cura para o glaucoma e a visão perdida não possa ser recuperada, o tratamento precoce pode retardar ou interromper a progressão da doença e preservar a visão restante. Melhores resultados do tratamento é quanto mais cedo o glaucoma é diagnosticado, maiores as chances de que os tratamentos com colírios, laser(trabeculoplastia (SLT/ALT), iridotomia e ciclotocoagulação a laser) e cirurgia (trabeculectomia, implante de válvula e cirurgias minimamente

invasivas) sejam eficazes na redução da pressão intraocular e na proteção do nervo óptico Ansari (2024).

Conforme orientações da Sociedade Brasileira de Glaucoma (2025), o acompanhamento periódico permite um monitoramento regular da pressão intraocular e do campo visual, ajustando o tratamento conforme necessário para manter a doença sob controle. Recomendação: exames periódicos para adultos com fatores de risco histórico familiar, idade avançada, diabetes, hipertensão, etnia afrodescendente.


## **2.2 Exames Oftalmológicos e Fontes de Dados**

### **2.2.1 Campo Visual (Perimetria)**

O exame de campo visual, também chamado de perimetria, é utilizado para avaliar a sensibilidade da retina a estímulos luminosos em diferentes pontos do campo visual. Este exame é fundamental para o diagnóstico e acompanhamento do glaucoma, pois permite detectar alterações precoces, mesmo antes de o paciente perceber perda de visão. O principal objetivo do exame é identificar defeitos do campo visual típicos do glaucoma, como escotomas localizados ou difusos. Monitorar a progressão da doença ao longo do tempo. E por fim fornecer informações para planejamento terapêutico, ajustando colírios, procedimentos a laser ou cirurgias CPC - Glaucoma Patients (2025).

A perimetria automatizada utiliza dispositivos computadorizados que aplicam estímulos luminosos em pontos específicos do campo visual. O paciente indica quando percebe a luz. Perimetria manual (Goldmann) realizada por examinador treinado, adequada para casos especiais ou crianças. As vantagens de detectar alterações precoces da função visual, permite o monitoramento objetivo da progressão do glaucoma, que pode ser padronizada e comparada ao longo do tempo. Existem limitações como depender da cooperação e atenção do paciente, os resultados podem variar com fadiga, distração ou ansiedade, não fornece informações estruturais do nervo óptico, sendo complementada por exames como OCT e retinografia Brasil (2021). Na figura 5 é apresentado o resultado do exame de campo visual no qual as partes escuras têm perda do campo de visão, retornando que na esquerda um olho normal e da direita um olho glaucomatoso, em escala de cinza Glaucoma Patients Association (2018).

Figura 5 – Comparação do campo visual.



Fonte: Glaucoma Patients Association (2018).

### 2.2.2 Tomografia de Coerência Óptica (OCT)

A Tomografia de Coerência Óptica (OCT) foi apresentada pela primeira vez por Huang *et al.* no ano de 1991 é um exame de imagem não invasivo que permite a visualização detalhada das estruturas oculares, principalmente a retina e o nervo óptico. É uma ferramenta essencial no diagnóstico precoce e acompanhamento do glaucoma, pois fornece informações estruturais que complementam os dados funcionais obtidos na perimetria.

O OCT utiliza radiação de luz de baixa coerência para gerar imagens transversais das camadas da retina. A diferença de reflexão da luz em cada camada permite medir espessuras e volumes, sendo possível identificar o afinamento da camada de fibras nervosas da retina (RNFL) e alterações do disco óptico Santos (2017).

Principais parâmetros avaliados a espessura da RNFL sua redução indica dano glaucomatoso, a camada de células ganglionares analisa a integridade neuronal, a escavação do disco óptico observa a escavação/disco avaliando a progressão da doença Medeiros (2025).

O benefício desse exame é o auxílio do diagnóstico precoce, mesmo antes da perda de visão perceptível, avaliação objetiva e quantitativa da estrutura do nervo óptico além de permitir monitoramento longitudinal da doença, comparando exames ao longo do tempo. As principais desvantagens desse equipamento muito caro e



disponibilidade limitada em algumas regiões, interpretação exige treinamento especializado, o resultados podem ser afetados por catarata, miopia alta ou outras patologias retinianas Bortoluci *et al.* (2013).

Machado e Jorge (2020) considera que a tomografia é de suma importância para o diagnóstico e o acompanhamento de diversas afecções do globo ocular, incluindo retina, coróide, vítreo, nervo óptico e segmento anterior.

### 2.2.3 Retinografia (Fundos de Olho)


A retinografia é um exame de imagem que captura fotografias do fundo de olho, permitindo a visualização do disco óptico, retina, vasos sanguíneos e mácula. Este exame é fundamental para o diagnóstico e acompanhamento do glaucoma, pois permite avaliar alterações estruturais do nervo óptico e da retina de forma objetiva e documentada. A retinografia utiliza uma câmera especializada com iluminação adequada para registrar imagens digitais do fundo do olho. Alguns modelos permitem a captura de imagens coloridas, infravermelhas ou com fluoresceína para estudo vascular Ivan *et al.* (2018).

Os parâmetros avaliados são do disco óptico o tamanho, a bordas e a relação escavação/disco, além da escavação do nervo óptico aumento progressivo indica dano glaucomatoso a alterações da retina e vasos podem indicar glaucoma secundário ou outras comorbidades Silva *et al.* (2018).

A vantagem do registro permanente da anatomia ocular para comparação ao longo do tempo auxilia diagnósticos estruturais precoces e acompanhamento da progressão da doença, é base para modelos de inteligência artificial, que analisam automaticamente padrões de dano óptico. Mas pode haver problemas como não fornecer informações funcionais do campo visual, a qualidade da imagem pode ser afetada por opacidades oculares, como catarata ou hemorragias vítreas e a interpretação depende do oftalmologista treinado, conforme Azevedo (2019). Na figura 6 é mostrado à esquerda: disco óptico com aparência normal, com tecido neural saudável e espesso. Centro: disco óptico com aparência glaucomatosa, com perda do tecido neural e aumento da escavação. Direita: estágio final do glaucoma, com escavação avançada e dano irreversível ao nervo óptico.



Figura 6 – Imagem do fundo do olho.



Fonte: Glaucoma Patients Association.

#### 2.2.4 Parâmetros Clínicos

Os parâmetros clínicos são indicadores essenciais para a avaliação, diagnóstico precoce e monitoramento do glaucoma, permitindo identificar risco de progressão da doença e orientar intervenções terapêuticas são eles:

1. A pressão intraocular (PIO) elevada é o fator de risco mais significativo e modificável para o glaucoma, causando compressão mecânica e degeneração das fibras do nervo óptico. No entanto, o dano ao nervo óptico pode ocorrer mesmo com níveis normais de PIO, caracterizando o glaucoma de pressão normal. A medição da PIO é realizada por tonometria (*Goldmann*, não invasiva ou a ar) Sakata (2000).
2. Escavação do disco óptico detectada por oftalmoscopia ou retinografia, a escavação é um sinal de perda progressiva de fibras nervosas. A relação escavação/disco (C/D ratio) é um indicador crucial, um aumento na escavação sugere dano glaucomatoso baseado em Ivan *et al.* (2018).

Espessura da Camada de Fibras Nervosas da Retina (RNFL) a redução da (RNFL), medida principalmente por meio do OCT, é um indicador precoce de glaucoma. Essa medição é crucial para o monitoramento longitudinal e a detecção precoce da progressão da doença, de acordo com Santos (2017).

A perimetria avalia o campo visual, identificando alterações funcionais resultantes de danos estruturais ao nervo óptico. As alterações comuns incluem escotomas (pontos cegos) localizados ou difusos, e em estágios avançados, perda da visão periférica ou central CPC (Glaucoma Patients, 2025).

O glaucoma é uma doença multifatorial, e a presença de certos elementos no histórico clínico e familiar do paciente pode elevar significativamente o risco de

desenvolvimento ou progressão da condição. Dentre os fatores de risco mais relevantes, destacam-se:

**Histórico familiar de glaucoma:** A predisposição genética é um fator crucial, indicando que indivíduos com parentes de primeiro grau diagnosticados com glaucoma possuem maior probabilidade de desenvolver a doença (Sociedade Brasileira de Glaucoma, 2025).

**Idade avançada:** O envelhecimento é um fator de risco não modificável, com a incidência de glaucoma aumentando progressivamente com a idade (Sociedade Brasileira de Glaucoma, 2025).

**Diabetes:** Pacientes diabéticos apresentam um risco elevado devido a alterações vasculares e metabólicas que podem comprometer a saúde ocular (Sociedade Brasileira de Glaucoma, 2025).

**Hipertensão:** A pressão arterial elevada sistemicamente pode influenciar a pressão intraocular e a saúde do nervo óptico, contribuindo para o risco de glaucoma (Sociedade Brasileira de Glaucoma, 2025).

**Etnia (afrodescendente):** Indivíduos de etnia afrodescendente demonstram uma maior prevalência e gravidade do glaucoma, o que sugere uma suscetibilidade genética (Sociedade Brasileira de Glaucoma, 2025).

A integração dos parâmetros para avaliação da saúde do nervo óptico e da função visual é crucial para a prática clínica. Isso permite a detecção precoce do glaucoma antes da perda visual irreversível, o monitoramento da progressão da doença e o apoio a decisões terapêuticas, como o ajuste de colírios, procedimentos a laser ou cirurgias, conforme a evolução da doença (Ansari 2024).

### **2.3 Machine Learning**

O Machine Learning tem se destacado como uma ferramentas poderosas no diagnóstico médico, incluindo a detecção precoce do glaucoma. Essas tecnologias permitem que sistemas computacionais aprendam padrões complexos a partir de grandes volumes de dados, apoiando decisões clínicas e aumentando a precisão diagnóstica. As aplicações no campo da oftalmologia são a análise automatizada de imagens de retinografia e OCT, predição de risco de progressão do glaucoma e suporte à decisão clínica, reduzindo erros humanos e otimizando o tempo do profissional Asaoka *et al.* (2016).

As vantagens do uso de ML incluem rapidez e eficiência, processa grandes volumes de dados em segundos é possível padronização reduz variação de interpretação entre profissionais e identifica padrões sutis antes de alterações perceptíveis ao exame clínico tradicional K. Sun *et al.*, (2024).

Mas existem algumas limitações como a necessidade de bases de dados grandes e anotadas, generalização para diferentes populações ainda é um desafio, a interpretação dos resultados requer supervisão de especialistas para evitar diagnósticos equivocados B. Vasey *et al.*, (2021).

### 2.3.1 Conceito Geral

O aprendizado de máquina pode ser subdivididos da seguinte forma:

1. Aprendizado supervisionado: os dados são rotulados; o algoritmo aprende a classificar ou prever resultados (Barros, 2020). Desse modo, torna-se possível identificar glaucoma em imagens de OCT.
2. Aprendizado não supervisionado: identifica padrões ou agrupamentos sem rótulos (Cavallari, 2022). Podendo assim identificar lesões na retina agrupando os casos separando dos casos normais.
3. Aprendizado por reforço: o algoritmo aprende por tentativa e erro, otimizando decisões com base em recompensas de feedback (Faceli *et al.*, 2011).

Contribuições para a o cenário de análise automatizada de exames de imagem (OCT, retinografia), permite prever risco de progressão da doença, suporta a triagem de grandes populações, reduzindo o tempo e custo do diagnóstico Santos Martins, (2021).

### 2.3.2 Algoritmos Usados

No contexto do diagnóstico do glaucoma com *Machine Learning*, diferentes algoritmos podem ser aplicados, dependendo do tipo de dados disponíveis e do objetivo do modelo (De Fauw, 2018). Destacam-se as Redes Neurais Convolucionais (CNN – *Convolutional Neural Networks*), especialmente indicadas para análise de imagens, como retinografia e OCT, pois extraem características relevantes e identificam padrões sutis de dano ao nervo óptico, permitindo a classificação de pacientes em grupos como “glaucoma” ou “saudável” (Moura Lima, 2020). Outro método é a Support Vector Machine (SVM), um algoritmo de aprendizado supervisionado utilizado para classificação que procura separar os dados em diferentes classes por meio de hiperplanos ótimos, sendo aplicado para

diferenciar imagens de pacientes com glaucoma daqueles sem a doença (Dey, Abhishek e Samir Bandyopadhyay, 2016).

Também se destaca o Random Forest, que consiste em um conjunto de árvores de decisão que trabalham em conjunto para aumentar a precisão e é indicado para dados clínicos estruturados, como pressão intraocular, idade e espessura da RNFL, fornecendo ainda a importância relativa de cada parâmetro clínico e auxiliando na interpretação médica (Shanmugam, P., J. Raja e R. Pitchai, 2021). Por fim, o K-Nearest Neighbors (KNN) baseia-se na similaridade entre casos, classificando um paciente com base nos exemplos mais próximos em termos de parâmetros clínicos ou características extraídas de imagens (Balasubramanian *et al.*, 2018).

### 2.3.3 Aplicações na Detecção Precoce do Glaucoma

A aplicação de *Machine Learning* no glaucoma visa identificar a doença antes do aparecimento de sintomas clínicos evidentes, aumentando significativamente a chance de preservação da visão. Com o algoritmo analisando imagens de retinografia e OCT, através de Redes Neurais Convolucionais (CNNs), podendo detectar alterações sutis no disco óptico e na camada de fibras nervosas da retina (RNFL), permitindo detecção precoce de glaucoma de ângulo aberto e pressão normal, mesmo antes de alterações perceptíveis na perimetria (Camara, 2023). Já algoritmos como Random Forest e SVM, analisam dados clínicos: PIO, idade, histórico familiar, espessura da RNFL, para prever a probabilidade de evolução da doença, auxiliando também na estratificação de pacientes de alto risco, priorizando acompanhamento intensivo e intervenção precoce (Lima *et al.*, 2019).

### 2.3.4 Exemplo de estudo acadêmico

Uma nova ferramenta de diagnóstico assistido por computador (CAD) foi desenvolvida e proposta para a detecção precoce de glaucoma, uma das principais causas de cegueira irreversível globalmente. Esta ferramenta utiliza uma sofisticada Rede Neural Convolucional (CNN) de 18 camadas, projetada especificamente para analisar imagens de fundo de olho. A eficácia da ferramenta foi validada através de um treinamento utilizando conjunto de dados composto por 1.426 imagens de fundo de olho. Destas, 589 imagens foram classificadas como normais, enquanto 837 apresentavam sinais de glaucoma. A diversidade e o volume deste conjunto de

dados contribuíram para o robusto aprendizado da CNN, permitindo que ela discernisse com alta precisão as características sutis associadas à presença da doença. Os resultados obtidos durante os testes de desempenho da ferramenta foram notavelmente promissores. A ferramenta CAD demonstrou uma impressionante taxa de precisão de 98,13%, indicando que a grande maioria de suas classificações estava correta. Além disso, alcançou uma sensibilidade de 98%, o que significa que a ferramenta foi altamente eficaz em identificar corretamente os casos positivos de glaucoma, minimizando o risco de falsos negativos. Complementarmente, a especificidade de 98,3% ressalta a capacidade da ferramenta de identificar corretamente os casos negativos, ou seja, de pacientes sem glaucoma, reduzindo a ocorrência de falsos positivos (Raghavendra *et al.*, 2018).

#### 2.3.5 Aplicações de *Machine Learning* na Medicina

Segundo Asaoka *et al.* (2016), o *Machine Learning* tem se consolidado como uma ferramenta revolucionária na medicina, permitindo que computadores aprendam padrões a partir de dados clínicos, laboratoriais e de imagem para apoiar decisões médicas e otimizar o diagnóstico e tratamento de diversas doenças. As principais áreas de aplicação incluem:

1. Diagnóstico assistido por computador, para identificação precoce de doenças como câncer, retinopatia diabética e glaucoma. Esses algoritmos analisam imagens médicas, exames laboratoriais e sinais clínicos, aumentando a precisão diagnóstica (Santos, 2020).
2. Predição de risco e prognóstico, onde modelos de ML estimam a probabilidade de ocorrência ou progressão de doenças, permitindo intervenção precoce. Exemplo: Predição de risco de mortalidade infantil em neonatos prematuros (Freitas, 2025).
3. Aplicações específicas em oftalmologia, onde há a detecção precoce de glaucoma através de análise automatizada de OCT, retinografia e campo visual. Desse modo, é possível prever a progressão do glaucoma, permitindo estratificação de risco e monitoramento intensivo, além de oferecer suporte em triagem populacional, tornando os programas de prevenção mais eficientes e econômicos (Russo *et al.*, 2024).

## 2.4 Trabalhos Relacionados

Nos últimos anos, diversos estudos têm explorado a aplicação de *Machine Learning* e Visão Computacional na oftalmologia, com foco na detecção precoce do glaucoma. Esses trabalhos demonstram o potencial dessas tecnologias para melhorar a acurácia diagnóstica, agilizar a análise de exames e apoiar decisões clínicas.

#### 2.4.1 Redes Neurais Convolucionais (CNNs) em retinografia

O estudo investiga a aplicação de modelos baseados em *Transformers* para detecção de glaucoma em retinografias obtidas por oftalmoscópio portátil, visando soluções acessíveis para regiões com recursos limitados. Os Transformers são uma arquitetura de rede neural que utiliza um mecanismo de *atenção*, capaz de analisar simultaneamente todos os elementos de uma imagem ou sequência e identificar as partes mais relevantes para a tarefa, o que permite capturar padrões complexos de forma eficiente. Diferentemente das redes convolucionais tradicionais, que dependem de filtros locais, os Transformers conseguem modelar relações globais entre diferentes regiões da imagem. Para a análise, foi utilizado um conjunto de 2.000 imagens de fundo de olho com qualidade reduzida, e os modelos SwinV2, BEiT, DeiT e ViT foram treinados e avaliados. Os resultados mostram que os Transformers alcançaram desempenho competitivo em relação a redes convolucionais tradicionais. A combinação das previsões dos modelos em um ensaio obteve acurácia média de 93,25%, demonstrando o potencial da abordagem para triagem automatizada de glaucoma em ambientes clínicos com restrições tecnológicas (Costa et al., 2025).

#### 2.4.2 Random Forest e Support Vector Machine (SVM) com dados clínicos

Este trabalho avaliou diferentes métodos de extração de características e classificação de imagens para auxiliar no diagnóstico do glaucoma. Foram utilizadas imagens da base pública RIM-ONE v2, onde foram desenvolvidos três modelos: o primeiro usou características não geométricas (como LBP, HOG, momentos de Zernike e filtros de Gabor); já o segundo modelo adicionou informações geométricas às do modelo anterior; por fim, o terceiro utilizou redes neurais convolucionais pré-treinadas, como MobileNet, VGG16, VGG19 e ResNet50, para extrair características automaticamente. Assim, após a redução da dimensionalidade com PCA, os dados foram classificados com diferentes algoritmos, como SVM, MLP,

k-NN, regressão logística e GBDT. O modelo que combinou as características não geométricas com o classificador SVM obteve o melhor desempenho, alcançando acurácia de 89,03%, sensibilidade de 86,59%, especificidade de 91,06% e AUC de 88,95% (Assis, 2020).

#### 2.4.3 Integração de OCT e perimetria com ML

O estudo concluiu que os classificadores de *machine learning* treinados com dados combinados da tomografia de coerência óptica (OCT) e da perimetria automatizada (PAA) foram eficazes na distinção entre olhos normais e com glaucoma. O melhor desempenho foi do classificador Random Forest (RAN), com área sob a curva ROC de 0,946 e sensibilidade de 95,16% com especificidade de 80%. A associação entre dados estruturais e funcionais aumentou significativamente a acurácia diagnóstica em relação ao uso do OCT isolado (Silva, 2020).

#### 2.4.4 Triagem populacional automatizada

Tradicionalmente, o rastreamento é realizado por especialistas por meio da análise do nervo óptico, pressão intraocular e exames complementares, como campo visual e tomografia de coerência óptica (OCT). No entanto, limitações logísticas e estruturais, especialmente em regiões afastadas de centros especializados, comprometem a eficácia desses programas. Esta tese propõe soluções inovadoras para a automação do rastreamento do glaucoma, com foco no uso de dispositivos portáteis e acessíveis (Camara, 2023).

Foram realizadas revisões sistemáticas sobre tecnologias aplicadas à triagem automática e métodos de aprendizado profundo voltados à segmentação e classificação de imagens da retina. Também foi elaborado um banco de dados próprio com vídeos e imagens obtidos via smartphone acoplado a lentes de baixo custo, avaliados por técnicas de inteligência artificial de última geração. Os resultados apontam o potencial de algoritmos de aprendizado profundo e técnicas de processamento de imagem para viabilizar diagnósticos automatizados e acessíveis, contribuindo para a democratização do rastreamento do glaucoma em larga escala (Camara, 2023).

### 3 CONTEXTO INVESTIGADO E SITUAÇÃO PROBLEMA

Este estudo foi desenvolvido em uma clínica de saúde especializada em oftalmologia, de médio porte, localizada na região Sudeste do Brasil. A instituição atua com foco no diagnóstico, monitoramento e tratamento de doenças oculares crônicas e progressivas, como o glaucoma, e atende pacientes tanto por convênios quanto particulares. Possui equipamentos modernos para realização de exames como retinografia, campimetria e tomografia de coerência óptica (OCT), além de contar com uma equipe de oftalmologistas, técnicos e assistentes clínicos.

Mesmo com a estrutura tecnológica disponível, a clínica enfrenta desafios importantes relacionados à demanda crescente por atendimentos, ao tempo necessário para análise manual dos exames e à necessidade de decisões clínicas cada vez mais rápidas e assertivas. Os exames realizados geram dados relevantes, que são armazenados de forma centralizada e digital, mas a análise desses dados ainda ocorre de forma tradicional, dependendo exclusivamente da interpretação visual dos especialistas.

Isso gera alguns gargalos no processo:

1. Tempo elevado entre exame e diagnóstico final, principalmente em períodos de alta demanda;
2. Subutilização dos dados clínicos armazenados, que poderiam alimentar sistemas de apoio à decisão;
3. Variações na interpretação dos exames, principalmente nos casos em que as alterações ainda são discretas;
4. Dificuldade de estabelecer triagens automatizadas, o que compromete a priorização de casos mais graves.

Em especial, o diagnóstico precoce do glaucoma apresenta desafios únicos. Por se tratar de uma doença silenciosa e de progressão lenta, muitos pacientes só recebem o diagnóstico em estágios mais avançados quando já há comprometimento visual irreversível. O uso de tecnologias de imagem como a OCT permite identificar alterações estruturais no nervo óptico antes da manifestação de sintomas, mas exige análise minuciosa e conhecimento técnico especializado.

Frente a esse cenário, torna-se evidente a necessidade de incorporar soluções tecnológicas que melhorem o fluxo de atendimento e o aproveitamento dos dados clínicos disponíveis. A proposta de desenvolvimento de um módulo de apoio baseado em *machine learning* surge como uma alternativa viável para automatizar



parte da triagem, destacar padrões compatíveis com o glaucoma em imagens de OCT e sinalizar casos de risco à equipe médica.

Essa abordagem visa não apenas otimizar o trabalho dos profissionais, mas também aumentar a segurança diagnóstica, reduzir atrasos no início do tratamento e garantir um atendimento mais eficiente e humanizado aos pacientes da clínica.

#### **4 INTERVENÇÃO ADOTADA**

Diante da situação observada e dos desafios enfrentados na triagem e diagnóstico precoce do glaucoma, propõe-se a criação e futura implementação de um módulo computacional baseado em *machine learning*, com o objetivo de apoiar o processo clínico da instituição por meio da análise inteligente de exames oftalmológicos.

A proposta parte da constatação de que, embora a clínica conte com estrutura tecnológica adequada, o uso efetivo de seus dados clínicos especialmente imagens de tomografia de coerência óptica ainda não está plenamente explorado. Assim, a intervenção visa utilizar esses dados de forma estruturada para desenvolver um sistema de triagem automatizada, capaz de sinalizar alterações compatíveis com sinais iniciais de glaucoma.

##### **4.1 Etapas previstas da intervenção**

###### **4.1.1 Coleta e organização dos dados clínicos e de imagem**


A etapa inicial compreende a extração de dados estruturados do sistema da clínica. O foco estará em laudos de pacientes com e sem diagnóstico de glaucoma, priorizando laudos confirmados. Serão incluídas imagens OCT de boa qualidade e informações adicionais como idade, histórico familiar, pressão intraocular (PIO) e campo visual.

Para garantir a privacidade, os dados serão anonimizados e organizados em um banco de dados estruturado, utilizando formatos como CSV para dados tabulares e DICOM/JPEG/PNG para imagens. As ferramentas Pandas e OpenCV serão empregadas para a manipulação e visualização desses dados.

Abaixo contém exemplos reais de exames de uma paciente no qual demonstra na figura 7 os exames de fundo de olho, na esquerda: disco óptico com aparência normal, à direita: mostra uma alteração no disco óptico. Na figura 8 exame de OCT olho direito apresenta normalidade e na figura 9 exame de OCT do olho esquerdo apresenta uma alteração. Em seguida na figura 10 exame de campo

visual, olho direito apresenta normalidade e na figura 11 exame de campo visual, olho esquerdo apresentando alteração.

**Figura 7** – Exames de fundo de olho.



Fonte: Própria (2025).



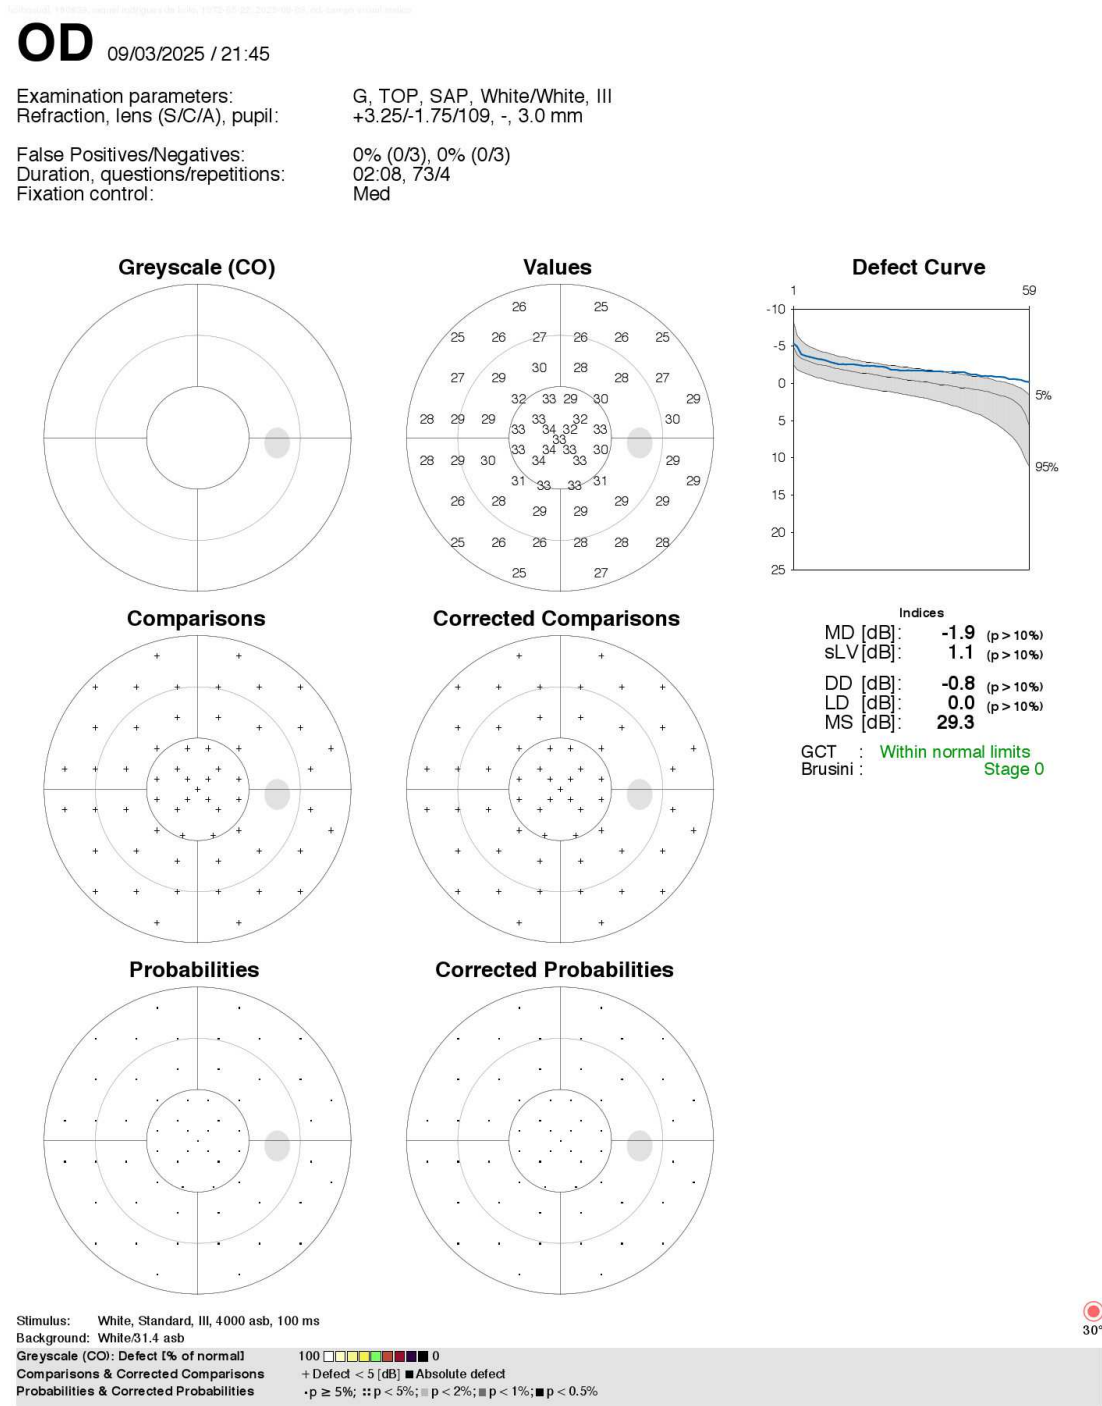
Figura 9 – Exame de OCT, olho esquerdo.

Optoscan®, 18/08/25, cauef@rodrigues.de.brito, 1970-02-02, 2005-09-04, v.1, tomografia de retina Optos



Fonte: Própria (2025)

Figura 10 – Exame de campo visual, olho direito.



Fonte: Própria (2025)

**Figura 11 – Exame de campo visual, olho esquerdo.**

**OS**

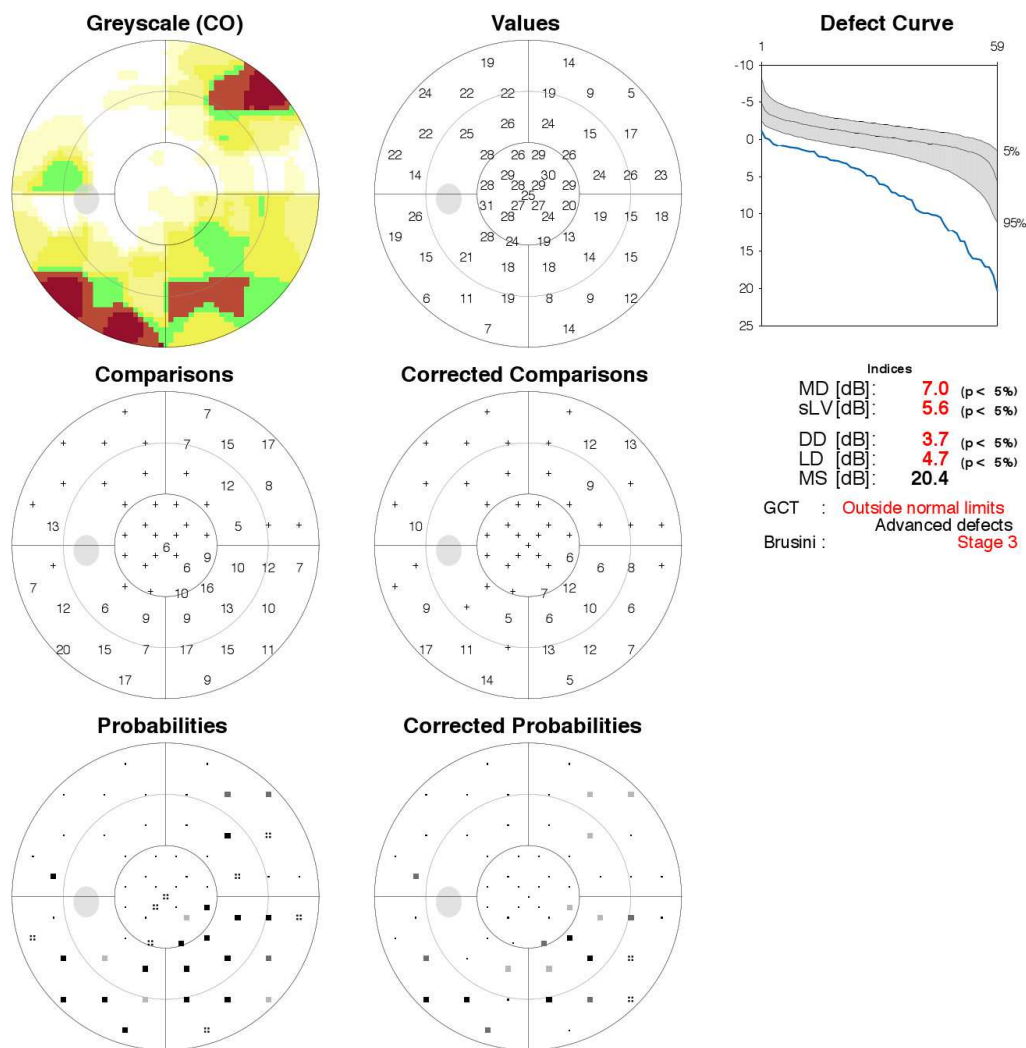
09/03/2025 / 21:49

Examination parameters:  
Refraction, lens (S/C/A), pupil:

G, TOP, SAP, White/White, III  
+3.75/-0.5/91, +4.0/-/-, 2.8 mm

False Positives/Negatives:  
Duration, questions/repetitions:  
Fixation control:

0% (0/5), 0% (0/5)  
03:46, 106/37  
Med



Stimulus: White, Standard, III, 4000 asb, 100 ms

Background: White31.4 asb

Greyscale (CO): Defect [% of normal]

Comparisons & Corrected Comparisons

Probabilities & Corrected Probabilities

100 0

+ Defect < 5 [dB] Absolute defect

- p ≥ 5%; :: p < 5%; ■ p < 2%; ■ p < 1%; ■ p < 0.5%

Fonte: Própria (2025)

#### 4.1.2 Pré-processamento das imagens

A uniformização de imagens é um processo essencial em diversas aplicações de visão computacional, visando garantir a consistência e a qualidade dos dados visuais. Esse processo envolve várias etapas cruciais.

Primeiramente, o redimensionamento das imagens é fundamental para padronizar suas dimensões. Isso é importante para que todos os dados de entrada tenham o mesmo tamanho, evitando distorções ou problemas de processamento em modelos que esperam um formato específico. Em seguida, a conversão para tons de cinza simplifica a representação das imagens. Ao reduzir a informação de cor para um único canal de intensidade luminosa, é possível diminuir a complexidade dos dados sem perder informações relevantes para certas tarefas, como detecção de bordas ou reconhecimento de padrões.

A remoção de artefatos é uma etapa crítica para eliminar ruídos, imperfeições ou objetos indesejados que possam comprometer a qualidade da imagem e influenciar negativamente o desempenho de algoritmos de processamento. Isso pode incluir a aplicação de filtros de suavização, remoção de manchas ou correção de distorções. A normalização é realizada para ajustar a faixa de valores dos pixels. Isso pode envolver a padronização do brilho e contraste, garantindo que as imagens possuam características visuais semelhantes, independentemente das condições de captura. Essa etapa é crucial para melhorar a robustez de modelos de aprendizado de máquina.

Por fim, o aumento de dados (data augmentation) é uma técnica utilizada para expandir o conjunto de treinamento através da criação de novas imagens a partir das existentes. Isso pode incluir rotações, espelhamentos, cortes aleatórios, alterações de brilho e contraste, entre outras transformações. O aumento de dados ajuda a melhorar a generalização dos modelos, tornando-os mais robustos a variações nas imagens de entrada e reduzindo o risco de overfitting.

Para a execução dessas tarefas, são utilizadas diversas bibliotecas de código aberto amplamente reconhecidas no campo da visão computacional:

1. OpenCV (Open Source Computer Vision Library): Uma das bibliotecas mais completas e utilizadas para processamento de imagens e visão computacional, oferecendo uma vasta gama de funções para manipulação, análise e transformação de imagens.



2. NumPy: Essencial para computação numérica em Python, o NumPy é amplamente utilizado em conjunto com o OpenCV para manipulação eficiente de arrays multidimensionais que representam as imagens.
3. imgaug: Uma biblioteca poderosa para aumento de dados, oferecendo uma interface flexível para aplicar diversas transformações geométricas e de cor nas imagens, com grande controle sobre os parâmetros e sequências de aumento.
4. Albumentations: Outra biblioteca popular para aumento de dados, focada em performance e facilidade de uso, especialmente em tarefas de aprendizado profundo. Oferece uma ampla variedade de transformações e otimizações para treinamento de modelos.

A combinação dessas técnicas e bibliotecas permite a criação de pipelines robustos e eficientes para a uniformização de imagens, garantindo a preparação adequada dos dados para análises posteriores ou treinamento de modelos.

#### 4.1.3 Extração de características

Este projeto explora duas abordagens distintas para análise de imagens: a primeira, tradicional, utiliza técnicas de processamento de imagem como Histogramas de Gradientes Orientados (HOG), Padrões Binários Locais (LBP) e Momentos de Zernike, além de estatísticas descritivas, implementadas com a biblioteca scikit-image em Python. A segunda abordagem, profunda, emprega Redes Neurais Convolucionais (CNNs) pré-treinadas, como VGG16 e ResNet50, aproveitando o poder do aprendizado de máquina para extração de características complexas e classificação, utilizando frameworks como TensorFlow/Keras ou PyTorch. Essa dualidade permite comparar a eficácia e as vantagens de cada metodologia em diferentes cenários de aplicação.

#### 4.1.4 Treinamento do modelo de aprendizado de máquina

Com a organização e pré-processamento dos dados concluídos, a próxima fase crucial envolve o desenvolvimento da solução utilizando algoritmos de aprendizado supervisionado. Serão empregados modelos robustos, como Random Forest, Support Vector Machines (SVM) e redes neurais (incluindo Multilayer Perceptrons - MLP e Convolutional Neural Networks - CNNs), para capacitar o sistema a identificar padrões complexos e sutis associados ao glaucoma.

Para garantir a máxima eficácia e confiabilidade do modelo, as imagens de treinamento serão criteriosamente avaliadas e anotadas por uma equipe de especialistas oftalmologistas. Essa avaliação humana é fundamental para a criação de um "ground truth" preciso, o que é indispensável para o treinamento supervisionado. A qualidade e a diversidade desse conjunto de dados anotados serão fatores determinantes para a capacidade do sistema de generalizar e identificar o glaucoma em novas imagens.

A escolha dos modelos supervisionados, como Random Forest, SVM, K-Nearest Neighbors (KNN), MLP e CNNs, baseia-se em suas comprovadas habilidades para lidar com dados de imagem e extrair características relevantes. Cada algoritmo será ajustado e otimizado para o conjunto de dados específico do glaucoma, explorando suas particularidades.

A avaliação do desempenho dos modelos será realizada através de um conjunto abrangente de métricas rigorosas, incluindo acurácia, sensibilidade, especificidade e a Área sob a Curva ROC (AUC). A acurácia medirá a proporção de previsões corretas totais, enquanto a sensibilidade (recall) indicará a capacidade do modelo de identificar corretamente os casos positivos (presença de glaucoma). A especificidade, por sua vez, avaliará a capacidade de identificar corretamente os casos negativos (ausência de glaucoma). A AUC fornecerá uma medida geral do poder discriminativo do modelo.

Para a implementação e avaliação desses modelos, serão utilizadas bibliotecas de aprendizado de máquina e *deep learning* de ponta, como scikit-learn, para algoritmos tradicionais, e TensorFlow e Keras, para o desenvolvimento e treinamento de redes neurais profundas. Essas ferramentas oferecem a flexibilidade e a capacidade de processamento necessárias para construir e refinar um sistema de diagnóstico de glaucoma de alta performance. O processo de desenvolvimento incluirá a validação cruzada para garantir a robustez e a generalização do modelo, minimizando o risco de overfitting.

#### 4.1.5 Validação e testes em ambiente controlado

Validação com holdout (70/30) ou k-fold, uso de conjunto de testes independente e matriz de confusão. Participação de oftalmologistas na validação clínica. A validação do modelo será rigorosa, utilizando-se tanto a técnica de holdout (70% para treinamento e 30% para teste) quanto a validação cruzada k-fold para garantir a robustez e generalização dos resultados. Além disso, a performance do

modelo será avaliada em um conjunto de testes completamente independente, que não foi utilizado em nenhuma etapa do treinamento ou ajuste dos hiperparâmetros, para evitar qualquer viés.

A avaliação do desempenho será detalhada através da matriz de confusão, permitindo uma análise aprofundada de métricas como acurácia, precisão, recall e F1-score, essenciais para compreender os tipos de erros e acertos do modelo.

Para a validação clínica, a participação ativa de oftalmologistas será crucial. Eles serão responsáveis por revisar e validar os resultados do modelo em casos reais, fornecendo feedback especializado sobre a aplicabilidade clínica e a interpretação dos achados, garantindo que a ferramenta seja clinicamente relevante e segura.

#### 4.1.6 Criação de um painel inteligente de triagem

Este painel interativo apresentará um ranking de risco dinâmico, utilizando um sistema de sinalização por cores intuitivas para destacar os diferentes níveis de perigo. A visualização das análises será clara e concisa, permitindo uma compreensão rápida dos dados.

Para o desenvolvimento, serão empregadas tecnologias de interface de usuário como Streamlit, Dash ou Flask, que oferecem flexibilidade e robustez para a criação de aplicações web interativas. O armazenamento e gerenciamento dos dados serão realizados através de um banco de dados SQLite, ideal para projetos que requerem simplicidade e portabilidade, ou por meio de uma API RESTful, garantindo escalabilidade e integração com outros sistemas. Esta combinação de tecnologias proporcionará uma ferramenta poderosa e de fácil utilização para o monitoramento e gestão de riscos.

#### 4.1.7 Integração ao sistema clínico da instituição

Após uma fase rigorosa de testes e validação, o módulo de análise automatizada será integrado ao sistema de gestão clínica já em uso, marcando um avanço significativo na otimização dos fluxos de trabalho. Esta integração permitirá que a análise de novas imagens de Tomografia de Coerência Óptica (OCT) seja realizada de forma automática e instantânea, logo após o upload.

O principal objetivo desta iniciativa é garantir que a nova ferramenta seja incorporada de maneira fluida à rotina diária da clínica, sem causar interrupções ou exigir mudanças drásticas nos procedimentos existentes. A automação visa não

apenas agilizar o processo de diagnóstico, mas também aprimorar a precisão e a consistência das análises.

Uma vez integradas, as imagens de OCT serão automaticamente analisadas pelo sistema, e os resultados serão salvos diretamente no prontuário eletrônico do paciente. Este processo garante um registro completo e de fácil acesso para os profissionais de saúde. Além disso, cada etapa da análise automatizada e do salvamento no prontuário será auditável, criando um histórico detalhado e seguro de todas as operações. Essa capacidade de auditoria é crucial para a conformidade regulatória e para a garantia da qualidade dos serviços prestados, oferecendo transparência e rastreabilidade para cada exame processado.

#### 4.1.8 Treinamento da equipe e acompanhamento contínuo

Será implementado um programa de capacitação abrangente para todos os profissionais envolvidos na operação e análise da ferramenta. Este treinamento incluirá módulos sobre a utilização técnica do painel, a interpretação correta dos resultados apresentados e a aplicação prática das informações geradas para tomadas de decisão estratégicas. O objetivo é garantir que a equipe possua o conhecimento e as habilidades necessárias para extrair o máximo valor da ferramenta.

Paralelamente à capacitação, o sistema será submetido a um monitoramento contínuo e rigoroso. Este monitoramento permitirá a identificação precoce de quaisquer inconsistências, falhas ou oportunidades de melhoria. Com base nos dados coletados e nas análises realizadas, serão feitos ajustes e otimizações de forma proativa. Este processo de aprendizado contínuo garantirá a evolução constante do modelo e sua eficácia, adaptando-o às necessidades em constante mudança do ambiente operacional e tecnológico. Um plano de evolução detalhado será estabelecido, prevendo atualizações periódicas e a incorporação de novas funcionalidades baseadas no feedback dos usuários e nas tendências tecnológicas.

## 5 RESULTADOS ALCANÇADOS (OU ESPERADOS)

A proposta de criação de um módulo computacional baseado em *machine learning* visa aprimorar o processo de triagem e diagnóstico precoce do glaucoma na prática clínica oftalmológica. Embora o sistema ainda esteja em fase de desenvolvimento, os resultados esperados foram projetados com base nas

evidências da literatura e nas demandas reais observadas na rotina da instituição estudada.

A seguir, estão os principais resultados esperados com a futura implementação da solução:

### **5.1 Melhoria na triagem e tomada de decisão**

O sistema no seu estágio final de validação será capaz de analisar automaticamente exames de tomografia de coerência óptica (OCT), após a realização do mesmo, visando que em alguns casos o paciente só retorna com o profissional de saúde após alguns dias ou até mesmo semanas, devido a disponibilidade de agenda do médico e do paciente. Dessa forma o painel alertará aqueles pacientes que apresentam padrões suspeitos de glaucoma. Com isso, os profissionais poderão identificar rapidamente pacientes que exigem atenção prioritária, reduzindo o tempo entre o exame e a conduta médica. A automação da triagem promove uma jornada mais fluida tanto para o médico quanto para o paciente.

### **5.2 Diagnóstico mais precoce e assertivo**

Por meio da detecção de alterações sutis no nervo óptico e na camada de fibras nervosas da retina, o modelo poderá indicar sinais iniciais da doença antes mesmo que sintomas visuais se manifestem. Isso aumenta significativamente a chance de intervenção precoce e preservação da visão, impactando diretamente na qualidade de vida dos pacientes.

### **5.3 Redução da variabilidade entre especialistas**

O apoio da análise automatizada permitirá padronizar a interpretação dos exames, reduzindo variações entre laudos de diferentes profissionais. Isso promove mais segurança nos diagnósticos, principalmente em casos limítrofes ou com alterações discretas, e fortalece a tomada de decisão médica baseada em dados.

### **5.4 Uso inteligente do banco de dados clínicos**

A clínica já dispõe de um acervo estruturado de imagens e laudos. A implementação do módulo permitirá reutilizar esses dados de forma estratégica, alimentando o modelo com casos reais e transformando o histórico da instituição em

uma base de conhecimento ativa. Além disso, o sistema poderá gerar relatórios analíticos que apoiem a gestão clínica e epidemiológica.

### **5.5 Otimização do tempo da equipe médica**

Ao automatizar a triagem inicial, o sistema desonera a equipe médica de tarefas repetitivas, permitindo que o foco esteja nos atendimentos de maior complexidade. Isso pode resultar em mais consultas realizadas por dia, melhor organização da agenda e maior tempo disponível para orientações ao paciente.

### **5.6 Melhoria da experiência do paciente**

Com diagnósticos mais rápidos, maior precisão nas análises e priorização de casos graves, os pacientes terão uma experiência de atendimento mais eficiente, resolutive e acolhedora. A confiança no serviço também tende a aumentar com o uso de tecnologias avançadas e com resultados mais transparentes.

### **5.7 Potencial de expansão**

O modelo desenvolvido poderá ser adaptado futuramente para detecção de outras doenças oculares, como retinopatia diabética ou degeneração macular. Além disso, sua estrutura modular permite replicação em outras unidades de saúde que disponham de exames semelhantes.

## **6 CONSIDERAÇÕES FINAIS**

Objetivou-se com este relato tecnológico apresentar os benefícios de um projeto-base de aplicação de aprendizado de máquina no diagnóstico de doenças oftalmológicas, com ênfase na detecção precoce do glaucoma.

O glaucoma, também conhecido como neuropatia óptica glaucomatosa, é uma doença crônica, progressiva e muitas vezes silenciosa, que afeta o nervo óptico e, se não for diagnosticada a tempo, pode levar à perda visual irreversível. Sua detecção precoce é um dos grandes desafios da oftalmologia, principalmente porque os sintomas muitas vezes só se manifestam em estágios avançados. Nesse contexto, torna-se fundamental buscar soluções tecnológicas que ampliem a capacidade de triagem, reduzam o tempo entre o exame e a conduta clínica e apoiem a tomada de decisões com maior precisão.

A proposta apresentada neste trabalho surge justamente como uma resposta a essa demanda, ao propor o desenvolvimento de um módulo computacional baseado em *machine learning* para apoiar o diagnóstico do glaucoma por meio da análise automatizada de exames de tomografia de coerência óptica (OCT). Ainda em fase de construção, a solução pretende atuar como um sistema de triagem inteligente, com capacidade de detectar alterações estruturais sutis no nervo óptico e sinalizar, de forma automática, os casos com maior probabilidade de alteração.

A intervenção, embora ainda não aplicada, foi cuidadosamente planejada com base em dados reais, estrutura tecnológica disponível na instituição estudada e evidências extraídas da literatura científica. Os resultados esperados demonstram que a aplicação de modelos computacionais pode contribuir significativamente para agilizar o fluxo de atendimento, reduzir a variabilidade diagnóstica, priorizar os pacientes de risco e promover o uso estratégico dos dados já armazenados na clínica. A ferramenta também poderá gerar indicadores em tempo real, apoiar programas de prevenção e até mesmo servir como base para estudos clínicos futuros.

Durante a construção do projeto, alguns desafios se mostraram relevantes:

1. A complexidade de lidar com dados sensíveis e a necessidade de anonimização para garantir a privacidade dos pacientes;
2. A exigência de uma base de dados ampla, padronizada e bem rotulada para que o algoritmo tenha desempenho confiável;
3. A necessidade de validação clínica rigorosa, com acompanhamento por profissionais qualificados;
4. A importância de manter a ferramenta como um apoio à decisão médica, jamais como substituto do olhar humano.

Esses fatores reforçam que a incorporação de tecnologias na saúde exige responsabilidade, planejamento e acompanhamento contínuo.

Por outro lado, o desenvolvimento deste relato também evidenciou diversas oportunidades e aprendizados importantes. A construção do projeto exigiu o domínio de conceitos de ciência de dados, análise de imagem, gestão da informação em saúde e compreensão do fluxo clínico. Isso reforça o caráter interdisciplinar de soluções baseadas em *machine learning*, que exigem a colaboração entre profissionais da saúde, da tecnologia e da gestão. Houve também o aprendizado de que, ao explorar melhor os dados já existentes, é possível gerar valor para o

atendimento clínico, economizar tempo e aumentar a assertividade no cuidado ao paciente.

Outro ponto importante está na escalabilidade da proposta. O sistema pode, futuramente, ser ajustado para detectar outras patologias oculares que também exigem monitoramento constante, como retinopatia diabética ou degeneração macular. Além disso, a proposta pode ser adaptada para diferentes contextos institucionais, como clínicas públicas, hospitais universitários ou redes de telemedicina, contribuindo para a democratização do acesso ao diagnóstico especializado.

Por fim, destaca-se que este projeto representa um passo importante na integração entre tecnologia e saúde, unindo inovação, responsabilidade social e visão preventiva. Ao propor uma solução acessível, baseada em evidências e aplicável na prática, o relato busca contribuir não apenas com a instituição analisada, mas com o debate mais amplo sobre o uso de tecnologias digitais para transformar o cuidado em saúde visual.

O sucesso da iniciativa dependerá do comprometimento da equipe envolvida, da qualidade dos dados, da constante atualização do sistema e, sobretudo, da compreensão de que a tecnologia deve servir como uma extensão da inteligência humana, nunca como substituto, mas como aliada.



## REFERÊNCIAS BIBLIOGRÁFICAS

A. Thacharodi et al., "**Revolutionizing healthcare and medicine**: The impact of modern technologies for a healthier future—A comprehensive review," Health Care Science, 2024. <https://doi.org/10.1002/hcs2.115>

ALCÂNTARA, Ednara Ponte de et al. **ATUALIZAÇÕES NO DIAGNÓSTICO E TRATAMENTO DO GLAUCOMA: AVANÇOS E DESAFIOS**. Revista Ibero-Americana de Humanidades, Ciências e Educação, [S. l.], v. 10, n. 8, p. 3784–3789, 2024. Disponível em: <https://periodicorease.pro.br/rease/article/view/15288>. Acesso em: 25 set. 2025. <https://doi.org/10.51891/rease.v10i8.15288>

ANSARI, R. R. **Glaucoma**: An overview on detection, diagnosis and treatment. StatPearls Publishing, Treasure Island (FL), 2024. Disponível em: <https://www.ncbi.nlm.nih.gov/books/NBK558962/>. Acesso em: 14 set. 2025.

ASSIS, D. F. de. **Avaliação de métodos de classificação de glaucoma em imagens de fundoscopia**. 2020. 107 f. Dissertação (Mestrado em Engenharia de Teleinformática) – Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2020. <https://doi.org/10.21528/CBIC2019-95>

AVANZO, M. **The evolution of artificial intelligence in medical imaging**. Insights into Imaging, v. 15, n. 1, 2024. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC11545079/>. Acesso em: 14 set. 2025.

AZEVEDO, Layane M.; DE ALMEIDA, João D. S. ; DE PAIVA, Anselmo C.; B. JUNIOR, Geraldo. **Diagnóstico de Glaucoma em Imagens de Fundo de Olho Usando Índices Taxonômicos**. In: ESCOLA REGIONAL DE COMPUTAÇÃO APLICADA À SAÚDE (ERCAS), 7. , 2019, Teresina. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2019. p. 43-48.

B. Vasey et al., "**Associação do desempenho diagnóstico clínico com sistemas de suporte à decisão baseados em aprendizado de máquina**: uma revisão sistemática", JAMA Network Open, 2021. <https://doi.org/10.21528/CBIC2019-95>

Balasubramanian, Kishore, NP Ananthamoorthy e K. Gayathridevi. "**Diagnóstico e classificação automáticos de glaucoma usando características híbridas e k-vizinho mais próximo**." Journal of Medical Imaging and Health Informatics 8.8 (2018): 1598-1606. <https://doi.org/10.1166/jmihi.2018.2504>

BARROS, Daniele Montenegro da Silva. **Uma arquitetura digital baseado em aprendizagem de máquina para diagnóstico de doenças oculares**: um estudo aplicado ao glaucoma. 2020.

BORTOLUCI, Matheus Sporleder; NOGUEIRA, Bruno Fontoura; DE ALMEIDA VARGAS, Jose Amadeu. **TOMOGRAFIA DE COERÊNCIA ÓPTICA—DESCRIÇÃO DA TÉCNICA E SUAS PRINCIPAIS APLICAÇÕES EM OFTALMOLOGIA**. Acta méd.(Porto Alegre), p. [7]-[7], 2013.

BRAGA, A. V.; LINS, A. F.; SOARES, L. S.; FLEURY, L. G.; CARVALHO, J. C.; PRADO, R. S. do. **Machine learning**: O Uso da Inteligência Artificial na Medicina/ Machine learning: The Use of Artificial Intelligence in Medicine. Brazilian Journal of Development, [S. l.], v. 5, n. 9, p. 16407–16413, 2019. Disponível em:

<https://ojs.brazilianjournals.com.br/ojs/index.php/BRJD/article/view/3437>. Acesso em: 25 set. 2025. <https://doi.org/10.34117/bjdv5n9-190>

BRASIL. Empresa Brasileira de Serviços Hospitalares. **Manual de campimetria computadorizada**. Juiz de Fora: EBSEH/HU-UFJF, 2021. Disponível em: <https://www.gov.br/ebserh-intensifica-assistencia-a-distancia-como-estrategia-de-combate-a-covid-19/pt-br/hospitais-universitarios/regiao-sudeste/hu-ufjf/aceso-a-informacao/nucleo-de-qualidade-hospitalar-gestao-de-documentos/gerencia-de-atencao-a-saude/unidade-de-cabeca-e-pescoco/man-ucap-oft-001-manual-de-campimetria-computadorizada.pdf>. Acesso em: 14 set. 2025.

BRASIL. Ministério da Saúde. **Principais doenças oculares**. Disponível em: <https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/d/doencas-oculares/principais-doencas-oculares>. Acesso em: 14 set. 2025.

CAVALLARI, Gabriel Biscaro. **Estudo de representações de imagens de múltiplos domínios a partir de aprendizado profundo não supervisionado e semi-supervisionado**. 2022. Tese de Doutorado. Universidade de São Paulo.

COSTA, Rodrigo Otávio C.; PIMENTEL, Patrik Oliveira; PESSOA, Alexandre Cesar P.; BRAZ JÚNIOR, Geraldo; ALMEIDA, João Dallyson S.. **Diagnóstico de Glaucoma em Retinografias de Oftalmoscópio Portátil Utilizando Ensemble Baseado em Transformers**. In: SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO APLICADA À SAÚDE (SBCAS), 25. , 2025, Porto Alegre/RS. Anais [...]. **Porto Alegre**: Sociedade Brasileira de Computação, 2025 . p. 449-460. ISSN 2763-8952. DOI: <https://doi.org/10.5753/sbcas.2025.7270>.

DA CAMARA, José Carlos Raposo. **Aspectos do rastreamento do glaucoma auxiliados por técnicas automatizadas em imagens com menor qualidade do disco óptico**. 2023. Tese de Doutorado. Universidade Aberta (Portugal).

De Fauw J, Ledsam JR, Romera-Paredes B, Nikolov S, Tomasev N, Blackwell S, et al. **Aprendizado profundo clinicamente aplicável para diagnóstico e encaminhamento em doenças da retina**. Nat Med. 2018;24(9):1342-50. <https://doi.org/10.1038/s41591-018-0107-6>

de Moura Lima, Alan Carlos, et al. **"Evolving convolutional neural networks for glaucoma diagnosis."** Brazilian Journal of Health Review 3.4 (2020): 9224-9234. <https://doi.org/10.34119/bjhrv3n4-160>

Dey, Abhishek e Samir Bandyopadhyay. **"Detecção automatizada de glaucoma usando o método de classificação por máquina de vetores de suporte."** British Journal of Medicine and Medical Research 11.12 (2016): 1-12.

dos Santos Martins, Thiago Gonçalves. **"Aprendizagem de máquina em análise de imagens na oftalmologia."** (2021).

EKUNDAYO, O. S. et al. **Deep learning**: Historical overview from inception to current developments. Applied Soft Computing, v. 153, 2025. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1568494625006891>. Acesso em: 14 set. 2025.

FACELI, K. et al. **Inteligência artificial**: uma abordagem de aprendizado de máquina. 1. ed. Rio de Janeiro: LTC, 2011.

FERNANDES, Arthur Guilherme Santos et al. **Meta aprendizagem de extração de características aplicada ao diagnóstico de glaucoma**. In: Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS). SBC, 2019. p. 342-347.  
<https://doi.org/10.5753/sbcas.2019.6273>

FRIEDMAN, David S. "Early Symptoms of Glaucoma". Mass General Brigham, 2024. Disponível em:  
<https://www.massgeneralbrigham.org/en/about/newsroom/articles/early-symptoms-of-glaucoma>. Acesso em: 14 set. 2025.

Figura 1 - Fonte: **PHELCOM** (2023). Disponível em:  
<https://phelcom.com/pt-br/blog/saude/tecnologia-detecta-glaucoma/>.

Figura 2 - Fonte: **IOC** (2023). Disponível em:  
<https://ioc.med.br/glaucoma-de-angulo-aberto/>. Acesso em: 14 set. 2025.

Figura 3 - Fonte: **Glaucoma Patients Association** (2018). Disponível em:  
<https://www.glaucomapatient.org/wp-content/uploads/2018/03/OCCLUDABLE-ANGLE-FIG-1.jpg>

Figura 4 - Fonte: **Glaucoma Patients Association** (2018). Disponível em:  
<https://www.glaucomapatient.org/wp-content/uploads/2018/03/replace-fig-2-congenital-glaucoma.jpg>

Figura 5 - Fonte: **Glaucoma Patients Association** (2018). Disponível em:  
<https://www.glaucomapatient.org/wp-content/uploads/2018/03/how-is-the-visual-field-examined.jpg>

Figura 6 - Fonte: **Glaucoma Patients Association**. Disponível em:  
<https://www.glaucomapatient.org/pt-br/basica-pt-br/disco-optico-glaucomatoso/.jpg>

Figura 7 - Fonte: Elaboração própria base de dados clínica.

Figura 8 - Fonte: Elaboração própria base de dados clínica.

Figura 9 - Fonte: Elaboração própria base de dados clínica.

Figura 10 - Fonte: Elaboração própria base de dados clínica.

Figura 11 - Fonte: Elaboração própria base de dados clínica.

Freitas, Gabriel Ribeiro de. **Predição de risco de mortalidade infantil em neonatos prematuros baseado em aprendizagem de máquina**. BS thesis. Universidade Federal do Rio Grande do Norte, 2025.

GLAUCOMA PATIENTS ASSOCIATION. **Quais são os testes feitos para diagnosticar glaucoma?** 2024. Disponível em:  
<https://www.glaucomapatient.org/pt-br/exame-ocular-pt-br/quais-sao-os-testes-feitos-para-diagnosticar-glaucoma/>. Acesso em: 14 set. 2025.

GPC – GLAUCOMA PATIENTS. **Como é feito o exame de campo visual**. Disponível em:  
<https://www.glaucomapatient.org/pt-br/exame-ocular-pt-br/como-e-feito-o-exame-de-campo-visual/>. Acesso em: 14 set. 2025.

GUI, J.; SUN, Z.; WEN, Y.; TAO, D.; YE, J. **A review on generative adversarial networks**: algorithms, theory, and applications. arXiv preprint, arXiv:2001.06937, 2020. Disponível em: <https://arxiv.org/abs/2001.06937>. Acesso em: 14 set. 2025.

HUSSAIN, A. H. et al. **Predicting glaucoma progression using deep learning**: A multimodal approach. Scientific Reports, v. 13, 2023. <https://doi.org/10.1038/s41598-023-46253-2>

IVAN, Y.; RAMGOPAL, S.; CARDENAS-VILLA, M.; et al. **Feasibility of the Digital Retinography System Camera in the Pediatric Emergency Department**. Pediatric Emergency Care, v. 34, n. 7, p. 488–491, 2018. <https://doi.org/10.1097/PEC.0000000000001203>

K. Sun et al., "**Modelos de base multimodal médica em diagnóstico e tratamento clínico**: aplicações, desafios e direções futuras", pré-impressão arXiv, 2024. Disponível em: <http://arxiv.org/pdf/2412.02621v1>

LEE, E. B.; WANG, S. Y.; CHANG, R. T. **Interpreting deep learning studies in glaucoma**: unresolved challenges. Asia-Pacific Journal of Ophthalmology, v. 10, n. 3, p. 264–271, 2021. Disponível em: [https://journals.lww.com/apjoo/fulltext/2021/06000/interpreting\\_deep\\_learning\\_studies\\_in\\_glaucoma\\_5.aspx](https://journals.lww.com/apjoo/fulltext/2021/06000/interpreting_deep_learning_studies_in_glaucoma_5.aspx). Acesso em: 14 set. 2025. <https://doi.org/10.1097/APO.0000000000000395>

LIMA, Alan Carlos de Moura et al. **Aprendizagem Profunda Aplicada ao Diagnóstico do Glaucoma**. 2019.

MACHADO, G. N.; JORGE, Y. Z. **Uso da tomografia de coerência óptica para análise do epitélio da córnea**. Mackenzie: Cutritiba, 2020.

MAETSCHKE, S.; ANTONY, B.; ISHIKAWA, H.; WOLLSTEIN, G.; SCHUMAN, J.; GARNAVI, R. **Uma abordagem agnóstica para detecção de glaucoma em volumes de OCT**. PLoS ONE, v. 14, n. 7, e0219126, 2019. Acesso em: 14 set. 2025. <https://doi.org/10.1371/journal.pone.0219126>

MALHEIROS, E. F. R.; BARBOSA, S. M.; BARBOSA, V. H. M.; CAPEL, A. C. T. F.; OLIVEIRA, M. de A. S.; SOUSA, L. M. de; ALVES, I. T.; AFIUNE, I. C. P.; MARRA, M. S.; MARRA, M. S.; OLIVEIRA, M. C. de; SANTAROSA, B. A.; NASSIF, J. G. P.; SAFA, S. N.; BEZERRA, F. Q. S. de B.; MORAIS, M. L. de. **GLAUCOMA: UMA PERSPECTIVA ABRANGENTE**. Brazilian Journal of Implantology and Health Sciences, [S. l.], v. 6, n. 2, p. 186–198, 2024. Disponível em: <https://bjih.emnuvens.com.br/bjih/article/view/1395>. Acesso em: 24 set. 2025. <https://doi.org/10.36557/2674-8169.2024v6n2p186-198>

MEDEIROS, Felipe de Araujo Andrade. **Comparação de métodos de imagem do disco óptico e da camada de fibras nervosas da retina para o diagnóstico do glaucoma**. 2005. Tese de Doutorado. Universidade de São Paulo.

MITCHELL, T. M. **Machine learning**. New York: McGraw-Hill, 1997.

N. Bagam, "**Applications of Machine Learning in Healthcare Data Analysis**," International journal of scientific research in computer science, engineering and information technology, 2020. <https://doi.org/10.32628/CSEIT206621>

POHL, H.; TARNUTZER, A. A. Acute angle-closure glaucoma. **The New England Journal of Medicine**, v. 378, n. 10, p. e14, 2018.  
<https://doi.org/10.1056/NEJMicm1712742>

RAGHAVENDRA, U.; FUJITA, Hamido; BHANDARY, Sulatha V.; GUDIGAR, Anjan; TAN, Jen Hong; ACHARYA, U. Rajendra. **Deep convolution neural network for accurate diagnosis of glaucoma using digital fundus images**. Information Sciences, Amsterdam, v. 441, p. 41–49, 2018. Disponível em:  
<https://www.sciencedirect.com/science/article/pii/S0020025518300744>. Acesso em: 14 set. 2025. <https://doi.org/10.1016/j.ins.2018.01.051>

REIS, L. M.; SEESE, S. E.; COSTAKOS, D.; SEMINA, E. V. **Congenital anterior segment ocular disorders**: genotype-phenotype correlations and emerging novel mechanisms. Progress in Retinal and Eye Research, v. 102, p. 101288, 2024.  
<https://doi.org/10.1016/j.preteyeres.2024.101288>

Russo, Lisa Mell Machado, et al. **"ABORDAGENS INOVADORAS NO DIAGNÓSTICO PRECOCE DO GLAUCOMA."** Brazilian Journal of Implantology and Health Sciences 6.3 (2024): 1548-1562.  
<https://doi.org/10.36557/2674-8169.2024v6n3p1548-1562>

Sakata, Kenji, et al. **"Estudo da correlação entre pressão intra-ocular e espessura corneana central (projeto glaucoma)."** Arquivos Brasileiros de Oftalmologia 63 (2000): 355-358. <https://doi.org/10.1590/S0004-27492000000500005>

SANTOS, A. P. M. **Análise da tomografia de coerência óptica em crianças e adolescentes com fatores de risco para o desenvolvimento do glaucoma**. 56 f. Monografia (Graduação em Medicina) - Universidade Federal do Maranhão (UFMA), São Luís, 2017.

Santos, Lidiane Ribeiro. **"Identificação da retinopatia diabética por aprendizado de máquina."** (2020).

SAVASTANO, M. C. et al. **Artificial intelligence in ophthalmology**: progress, challenges, and the path forward. [S.l.]: [s.n.], 2025. Disponível em:  
<https://pubmed.ncbi.nlm.nih.gov/40453785>. Acesso em: 14 set. 2025.

SHAHRIARI, M. H. et al. **Applications of machine learning in glaucoma diagnosis based on tabular data**: a systematic review. BMC Biomedical Engineering, v. 5, n. 1, 2025. Disponível em:  
<https://bmcbiomedeng.biomedcentral.com/articles/10.1186/s42490-025-00095-3>. Acesso em: 14 set. 2025. <https://doi.org/10.1186/s42490-025-00095-3>

SHAHRIARI, M.; DARVISH, A. **Clinical decision support systems in ophthalmology**: a systematic search and narrative review. Applied Medical Informatics, Cluj-Napoca, v. 46, n. 3, p. 70–82, 2024. Disponível em:  
<https://www.researchgate.net/publication/384464618>. Acesso em: 14 set. 2025.

Shanmugam, P., J. Raja e R. Pitchai. **"Um reconhecimento automático de glaucoma em imagens de fundo de olho usando aprendizado profundo e classificador de floresta aleatória."** Applied Soft Computing 109 (2021): 107512.

SHARTS-HOPKO, N. C.; GLYNN-MILLEY, C. **Primary open-angle glaucoma**. **American Journal of Nursing**, v. 109, n. 2, p. 40–47, fev. 2009.  
<https://doi.org/10.1097/01.NAJ.0000345434.37734.ee>

SILVA, Fabrício Reis. **Classificadores de aprendizagem de máquina e tomografia de coerência óptica de domínio espectral no diagnóstico do glaucoma**. 2020. Dissertação (Mestrado em Ciências da Saúde) – Universidade Federal do Espírito Santo, Vitória, 2020.

SILVA, Mayara G. et al. **Diagnóstico do glaucoma em imagens de retinografia usando variantes de padrões locais binários**. In: Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS). SBC, 2018.  
<https://doi.org/10.5753/sbcas.2018.3679>

SOCIEDADE BRASILEIRA DE GLAUCOMA. **Material informativo para pacientes**. 2025. Disponível em: <https://www.sbglaucoma.org.br/paciente/material-informativo/>. Acesso em: 14 set. 2025.

STATPEARLS. **Physiology, aqueous humor circulation**. In: STATPEARLS [Internet]. Treasure Island (FL): StatPearls Publishing; 2023. Disponível em: <https://www.ncbi.nlm.nih.gov/books/NBK553209/>. Acesso em: 14 set. 2025.

SUSANNA JR., R. **Glaucoma**. Rio de Janeiro: Cultura Médica; Guanabara Koogan, 2020.

ŚWIERCZYŃSKI, H. et al. **Application of machine learning techniques in GlaucomAI system for glaucoma diagnosis and collaborative research support**. Scientific Reports, [S.l.], v. 15, art. 7940, 2025. Disponível em: <https://www.nature.com/articles/s41598-025-89893-2>. Acesso em: 14 set. 2025.

TAVARES, I. M.; MELLO, P. A. **Glaucoma de pressão normal** [Normal tension glaucoma]. Arquivos Brasileiros de Oftalmologia, v. 68, n. 4, p. 565–575, 2005.  
<https://doi.org/10.1590/S0004-27492005000400028>

TAURION, Cezar. **Big data**. Brasport, 2013.

TING, D. S. W. et al. **Artificial intelligence and deep learning in ophthalmology**. British Journal of Ophthalmology, v. 103, n. 2, p. 167–175, 2019. Disponível em: <https://bjo.bmj.com/content/103/2/167>. Acesso em: 14 set. 2025.  
<https://doi.org/10.1136/bjophthalmol-2018-313173>

TONTI, E. et al. **Artificial intelligence and advanced technology in glaucoma**. Journal of Personalized Medicine, v. 14, n. 10, p. 1062, 2024. Disponível em: <https://www.mdpi.com/2075-4426/14/10/1062>. Acesso em: 14 set. 2025.  
<https://doi.org/10.3390/jpm14101062>

WANG, X. et al. **The association between vascular abnormalities and retinal nerve fiber layer thinning in glaucoma**. Investigative Ophthalmology & Visual Science, v. 64, n. 5, 2023. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10487550/>. Acesso em: 14 set. 2025.

WITMER, R. **Sekundäre Glaukomformen** [Secondary forms of glaucoma]. Klinische Monatsblätter für Augenheilkunde, v. 189, n. 3, p. 187–189, 1986.  
<https://doi.org/10.1055/s-2008-1050783>

ZHANG, J.; et al. **A scoping review of advancements in machine learning for glaucoma: diagnosis, progression, treatment responses and personalized strategies**. Frontiers in Ophthalmology, 2025. Acesso em: 14 set. 2025.  
<https://doi.org/10.3389/fopht.2024.1368081>

ZHOU, Bolei; KRAHENBÜHL, Philipp; SHELHAMER, Evan; TORRALBA, Antonio.  
**Learning deep features for discriminative localization.** In: PROCEEDINGS OF  
THE IEEE CONFERENCE ON COMPUTER VISION AND PATTERN  
RECOGNITION, Las Vegas, NV, USA. [S. l.]: IEEE, 2016. p. 2921–2929.  
<https://doi.org/10.1109/CVPR.2016.319>