UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

Trabalho de Conclusão de Curso

ALGORITMO PARA SEGMENTAÇÃO DE DRUSAS EM IMAGENS DE RETINOGRAFIA ATRAVÉS DE TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS

Síntia Raianne Bezerra de Souza

Natal/RN
2025

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

CENTRO DE TECNOLOGIA

DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

ALGORITMO PARA SEGMENTAÇÃO DE DRUSAS EM IMAGENS DE RETINOGRAFIA ATRAVÉS DE TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS

Trabalho de conclusão de curso apresentado ao Departamento de Engenharia Biomédica da Universidade Federal do Rio Grande do Norte para obtenção do título de Graduada em Engenharia Biomédica.

Graduanda: Síntia Raianne Bezerra de Souza

Orientadora: Prof.ª Dra. Heliana Bezerra Soares

Natal/RN
2025

Universidade Federal do Rio Grande do Norte - UFRN
Sistema de Bibliotecas - SISBI
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Souza, Sintia Raianne Bezerra de.
Algoritmo para segmentação de drusas em imagens de retinografia através de técnicas de processamento digital de imagens / Sintia Raianne Bezerra de Souza. - 2025.
73f.: il.

Monografia (Graduação) - Universidade Federal do Rio Grande do Norte, Centro de Tecnologia, Curso de Engenharia Biomédica, Natal, 2025.
Orientação: Profª. Dra. Heliana Bezerra Soares.

1. Degeneração Macular Relacionada à Idade - Monografia. 2. Segmentação - Monografia. 3. Drusas - Monografia. 4. Processamento digital de imagens - Monografia. 5. Retinografia - Monografia. I. Soares, Heliana Bezerra. II. Título.

RN/UF/BCZM CDU 62:61

Elaborado por Raimundo Muniz de Oliveira - CRB-15/429

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

CENTRO DE TECNOLOGIA

DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

ALGORITMO PARA SEGMENTAÇÃO DE DRUSAS EM IMAGENS DE RETINOGRAFIA ATRAVÉS DE TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS

Banca Examinadora do Trabalho de Conclusão de Curso:

Profª. Dra. Heliana Bezerra Soares Orientadora	_____
Prof.ª Dr.ª Caroline Dantas Vilar Avaliadora Interna	_____
Prof. Dr. Anthony Andrey Ramalho Diniz Avaliador Externo	_____

Natal/RN

2025

DEDICATÓRIA

Dedico este trabalho, primeiramente, a Deus, por me conceder força e coragem. À minha mãe, pelo apoio e constante incentivo durante todo o curso. Ao meu namorado, Willisson, que esteve sempre ao meu lado, acreditando nos meus sonhos e na minha dedicação. E à minha amiga Natália, por seu apoio, que me encorajou e não permitiu que eu desistisse.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por guiar meus passos e iluminar meu caminho, me proporcionar inúmeras bênçãos, sabedoria e discernimento. Por ajudar a conquistar meus objetivos e superar todos os desafios encontrados ao longo da trajetória, com força, coragem e perseverança.

À minha mãe, Raimunda e meu padrasto, Abrahão, por todo amor, carinho, dedicação, apoio e incentivo que sempre me ofereceram. Vocês foram meu alicerce em momentos de dúvidas e dificuldades. Ao meu namorado Willisson, por estar sempre ao meu lado, compartilhando comigo essa jornada e me oferecendo apoio emocional, companheirismo inigualáveis e acreditar no meu potencial.

Agradeço também a minha amiga de infância, Bárbara, pela sua amizade sincera, todo seu amor, carinho, apoio e parceria ao longo desses anos. Seus conselhos foram valiosos e sua presença foi essencial para esta conquista.

À minha amiga, Natália, que conquistei ao longo do curso de Engenharia Biomédica, por não me deixar fraquejar nos momentos de dúvida e ansiedade, estando sempre ao meu lado, me apoiando e motivando a seguir em frente. Também expresso minha gratidão aos amigos que conquistei ao longo do curso, o apoio e contribuição de cada um de vocês foi muito importante, para que eu persistisse e concluísse esta etapa tão significativa.

Por fim, expresso minha enorme gratidão à minha orientadora e professora, Heliana. Sua paciência, sabedoria e ensinamentos foram cruciais para o meu crescimento acadêmico e pessoal, desde o tempo do grupo de pesquisa, no LABSIM. Seu comprometimento e dedicação inspiram a todos que têm o privilégio de aprender com você.

EPÍGRAFE

“O sucesso não é definitivo, o fracasso não é fatal: o que importa é a coragem de continuar” (Winston Churchill).

SUMARIO

LISTA DE FIGURAS x

LISTA DE TABELAS xii

LISTA DE EQUAÇÕES xiii

LISTA DE ABREVIAÇÕES, SIGLAS E SÍMBOLOS xiv

RESUMO xvi

ABSTRACT xvii

1. INTRODUÇÃO 1

1.1 OBJETIVOS 3

1.1.1 OBJETIVOS GERAL 3

1.1.2 OBJETIVOS ESPECÍFICO 3

1.2 ESTADO DA ARTE 4

1.3 ORGANIZAÇÃO DO TRABALHO 6

2. O OLHO 7

2.1 RETINA 8

2.2 DEGENERAÇÃO MACULAR RELACIONADA À IDADE (DMRI) 10

2.2.1 CLASSIFICAÇÃO DOS ESTÁGIOS DE PROGRESSÃO 12

2.2.2 DIAGNÓSTICO POR IMAGEM 13

2.2.2.1 RETINOGRAFIA COLORIDA 14

3. PROCESSAMENTO DIGITAL DE IMAGENS 18

3.1 CONTEXTUALIZAÇÃO HISTÓRICA 18

3.2 CONCEITOS FUNDAMENTAIS 20

3.2.1 TONS DE CINZA 21

3.2.2 MODELOS RGB DE CORES 22

3.2.3 EQUALIZAÇÃO DE HISTOGRAMA 23

3.2.4 MORFOLOGIA MATEMÁTICA 24

3.2.5 LIMIARIZAÇÃO 26

3.2.6 MÁSCARA GAUSSIANA 2D 27
3.2.7 DISTÂNCIA EUCLIDIANA 28
3.2.8 SEGMENTAÇÃO: MÉTODO *K - MEANS* 28
4. MATERIAIS E MÉTODOS 30
4.1 MATERIAIS 30
4.1.1 BANCO DE DADOS 30
4.1.2 MATLAB 31
4.2 MÉTODOS 31
4.3 PRÉ-PROCESSAMENTO 32
4.4 PROCESSAMENTO 36
4.5 PÓS-PROCESSAMENTO 37
5. RESULTADOS E DISCUSSÕES 40
5.1 RESULTADOS 40
5.1.1 MÉTRICAS E CLASSIFICAÇÕES DE AVALIAÇÃO 40
5.1.2 COMPARAÇÃO ENTRE A SEGMENTAÇÃO PROPOSTA E A MÁSCARA MODELO CRIADA 41
5.1.3 COMPARAÇÃO ENTRE A SEGMENTAÇÃO PROPOSTA E ALGORTIMOS DA LITERATURA 45
5.2 DISCUSSÕES 46
6. CONCLUSÕES 50
6.1 TRABALHOS FUTUROS 51
7. REFERÊNCIAS BIBLIOGRÁFICAS 53

LISTA DE FIGURAS

Figura. 1: Anatomia do olho humano, (a) olho em secção transversal e (b) olho em visão geral. 7

Figura. 2 : Anatomia e organização das camadas da retina. 8

Figura. 3: Vista da parede posterior do olho a partir de um oftalmoscópio. 9

Figura. 4: Classificação das drusas na forma seca. (a) drusas duras (b) drusas moles. 11

Figura. 5: Indícios de DMRI exsudativa. (a) neovascularização como área cinza-esverdeada subfoveal, (b) depósito de lipídeos de forma densa, (c) hemorragia intra e sub-retiniana e (d) cicatriz disciforme. 12

Figura. 6: Classificação dos estágios de progressão das drusas. (a) sem DMRI, (b) DMRI em estágio inicial, (c) DMRI intermediária, (d) DMRI avançada 13

Figura. 7: Retinógrafo convencional. 15

Figura. 8: Posicionamento do paciente frente retinógrafo (Manual de Treinamento de Aquisição de Retinografia – Projeto ELSA, 2009). 16

Figura. 9: Exemplo da retinografia colorida. 16

Figura. 10: Fluxograma dos processos de PDI e ADI. 19

Figura. 11: Escala de cinza.. 21

Figura. 12 : Escala de cinza: (a) imagem original em RGB (b) imagem em níveis de cinza. 22

Figura. 13: Formação da imagem no modelo RGB. 22

Figura. 14: Imagem RGB, (a) canal vermelho da imagem, (b) canal verde da imagem e (c) canal azul da imagem. 23

Figura. 15: Imagem e histogramas das imagens, (a) imagem escura, (b) imagem clara, (c) imagem de baixo contraste e (d) imagem de alto contraste. 24

Figura. 16: (a) conjunto, (b) elemento estruturante, (c), conjunto preenchido com os elementos de fundo para formar arranjo matricial (d) elemento estruturante no arranjo matricial retangular e (e) conjunto processado com elemento estruturante. 25

Figura. 17: Processamento morfológico de abertura, (a) objeto (b) elemento estruturante e (c) resultado da erosão e d) resultado da abertura. 26

Figura. 18: Limiarização por intensidade, (a) imagem original em níveis de cinza e (b) imagem binarizada. 27

Figura. 19: Exemplo da aplicação do algoritmo de agrupamento *K-means*, (a) k = 2, (b) k = 3, (c) k = 10 e (d) imagem original. 29

Figura. 20: Diagrama de Blocos da Estratégia de Segmentação. _____ 32
Figura. 21: Binarização, (a) imagem original, (b) imagem binarizada. _____ 33
Figura. 22: Binarização, (a) imagem original com sombra e regiões escuras e (b) imagem binarizada. _____ 33
Figura. 23: Remoção do background, (a) imagem binarizada com operação de abertura e (b) imagem com background removido. _____ 34
Figura. 24: Extração dos canais de cor, (a) imagem original, (b) canal vermelho da imagem, (c) canal verde da imagem e (d) canal azul da imagem. _____ 35
Figura. 25*:* Realce da região central da imagem, (a) imagem em níveis de cinza, (b) imagem após aplicação da Máscara Gaussiana e filtro de CLAHE. _____ 36
Figura. 26: Segmentação das drusas, (a) imagem após aplicação da Máscara Gaussiana e filtro de CLAHE e (b) imagem resultante após segmentação *K-means*. _____ 37
Figura. 27: Diagrama de Blocos da Estratégia de Segmentação Aprimorad*a* _____ 38
Figura. 28: Segmentação da região central, (a) imagem resultante após segmentação *K-means* e (b) imagem resultante da segmentação após aplicação da Máscara Circular._____ 39
Figura. 29: Comparação nos cenário criados, (a) imagem resultante da segmentação e (b) máscara modelo geral, (c) imagem resultante do pós-processamento e (d) máscara modelo central. _____ 42
Figura. 30: Resultado da segmentação e aplicação da máscara circular, (a) imagem com dico optico segmentado e extraido (b) imagem com região central com alta luminosidade segmentada e extraida e (c) imagem com drusas segmentadas e extração da região central. _____ 47
Figura. 31: Resultado da segmentação e aplicação da máscara circular, (a) imagem com dico optico segmentado e (b) imagem com região central com alta luminosidade.___ 48
Figura. 32: (a) imagem realçada e (b) imagen com drusas insuficientes. _____48
Figura. 33: Resultado da aplicação do algoritmo, (a) imagem final com disco óptico e drusas identificados, (b) imagem final com DO e região central extraída, (c) imagem final sem artefato e (d) imagem final sem artefatos com região central extraída. _____49

LISTA DE TABELAS

Tabela 1: Desempenho do algoritmo de segmentação das drusas sem máscara circular. _____ 43

Tabela 2: Desempenho do algoritmo de segmentação das drusas com máscara circular. _____ 44

Tabela 3: Comparação entre os métodos da literatura e o do algoritmo proposto. ___ 45

LISTA DE EQUAÇÕES

Equação (1): Transformação para Cinza _____ 21
Equação (2): Máscara Gaussiana 2D _____ 27
Equação (3): Máscara Gaussiana 2D Simplificada _____ 27
Equação (4): Distância Euclidiana _____ 28
Equação (5): Acurácia _____ 41
Equação (6): Sensibilidade _____ 41
Equação (7): Especificidade _____ 41

LISTA DE ABREVIAÇÕES, SIGLAS E SÍMBOLOS

ADAM - Detecção Automática da Degeneração Macular Relacionada à Idade

ADI - Análise Digital de Imagens

AREDS - Estudo sobre Doenças Oculares Relacionadas à Idade (*Age-Related Eye Disease Study*)

BrM - Membrana de Bruch

CLAHE - *Contrast Limited Adaptive Histogram Equalization*

CNNs - *Convolutional neural network*

DICOM - *Digital Imaging and Communications in Medicine*

DMRI - Degeneração Macular Relacionada à Idade

DO - Disco Óptico

EE - Elemento Estruturante

EPR - Epitélio Pigmentar da Retina

FA - Fluoresceína Angiografia

FN - Falso Negativo (*False Negative*)

FOV - *Field of View*

FP - Falso Positivo (*False Positive*)

HIS - Matriz, Saturação, Intensidade

HOG - *Histogram of Oriented Gradients*

ISBI - Simpósio Internacional de Imagem Biomédica

JPEG - *Joint Photographic Experts Group*

KNN - *K-Nearest Neighbors*

NASA - Administração Nacional de Aeronáutica e Espaço

NPID - Discriminação de Instância Não Paramétrica

OCT - Tomografia de Coerência Óptica

OCTA - Tomografia de Coerência Óptica Angiográfica

PACS - Sistema de Comunicação e Arquivamento de Imagens

PADI - Processamento e Análise Digital de Imagens

PDT - Terapia Fotodinâmica

PDI - Processamento Digital de Imagens

PPM - *Portable Pixmap Format*

RGB - Vermelho (*Red*), Verde (*Green*) e Azul (*Blue*)

ROI - Região de interesse (*Region of interest*)

STARE - *Structured Analysis of the Retina*

SVM - *Support Vector Machines*

TES - Tratar e Estender

TIFF - *Tagged Image File Format*

TN - Verdadeiro Negativo (*True Negative*)

TP - Verdadeiro Positivo (*True Positive*)

UV - Luz Ultravioleta

VEGF - Fator de Crescimento Endotelial Vascular (*Vascular Endothelial Growth Factor*)

SOUZA, Síntia Raianne Bezerra de. **Algoritmo para segmentação de drusas em imagens de retinografia através de técnicas de processamento digital de imagens.** Trabalho de Conclusão de Curso, Graduação em Engenharia Biomédica, Universidade Federal do Rio Grande do Norte, 74p., 2025.

RESUMO

A elevação da expectativa de vida nas últimas décadas, tem gerado novos desafios significativos à saúde pública no mundo, que estão associados a doenças relacionadas ao envelhecimento da população. Dentre essas condições, a Degeneração Macular Relacionada à Idade (DMRI) representa uma das principais causas de perda progressiva da visão e cegueira irreversível em idosos. O diagnóstico da DMRI ocorre por meio de exames oftalmológicos, como por exemplo a retinografia, que consiste na captura de imagens de alta resolução do fundo do olho. Esse exame permite a visualização das estruturas da retina e a identificação de alterações, como as drusas, que representa um dos principais marcadores da doença. A detecção precoce da DMRI possibilita intervenções que retardam a progressão da perda total da visão. Dessa forma, esse trabalho desenvolveu um algoritmo com o objetivo de auxiliar os profissionais na visualização da região e identificação das drusas, a partir da segmentação das drusas em imagens de retinografia, utilizando técnicas básicas de processamento digital de imagens. Para o desenvolvimento da estratégia foram aplicadas técnicas básicas de processamento digital de imagens, como: limiarização, morfologia matemática, equalização de histograma e segmentação por *k-means*. A partir da extração da região de interesse, os resultados foram comparados com outros estudos publicados na literatura, a fim de avaliar a eficácia e o desempenho do método proposto. Os resultados alcançados, com acurácia de 97,53% e especificidade de 99,18%, indicaram um elevado grau de exatidão e confiabilidade no desempenho do algoritmo.

Palavras-chave: Degeneração Macular Relacionada à Idade, segmentação, drusas, processamento digital de imagens e retinografia.

SOUZA, Síntia Raianne Bezerra de. **Algorithm for segmenting drusen in retinography images using digital image processing techniques.** Conclusion Work Project, Biomedical Engineering Bachelor Degree, Federal University of Rio Grande do Norte, 74p., 2025.

ABSTRACT

The increase in life expectancy in recent decades has created significant new challenges to public health worldwide, which are associated with diseases related to the aging of the population. Among these conditions, Age-Related Macular Degeneration (AMD) represents one of the main causes of progressive vision loss and irreversible blindness in the elderly. AMD is diagnosed through ophthalmological examinations, such as retinography, which consists of capturing high-resolution images of the back of the eye. This examination allows the visualization of the structures of the retina and the identification of changes, such as drusen, which represent one of the main markers of the disease. Early detection of AMD enables interventions that slow the progression of total vision loss. Thus, this work developed an algorithm with the objective of assisting professionals in visualizing the region and identifying drusen, based on the segmentation of drusen in retinography images, using basic digital image processing techniques. Basic digital image processing techniques were applied to develop the strategy, such as: thresholding, mathematical morphology, histogram equalization and k-means segmentation. After extracting the region of interest, the results were compared with other studies published in the literature in order to evaluate the effectiveness and performance of the proposed method. The results achieved, with an accuracy of 97.53% and specificity of 99.18%, indicated a high degree of accuracy and reliability in the performance of the algorithm.

Palavras-chave: Age-Related Macular Degeneration, segmentation, drusen, digital image processing and retinography.

1. INTRODUÇÃO

O aumento da expectativa de vida observado nas últimas décadas implicou no surgimento de novos desafios de saúde pública, que estão associados a doenças relacionadas ao envelhecimento. Dentre essas condições, a Degeneração Macular Relacionada à Idade (DMRI) representa uma das principais causas de perda severa da visão e cegueira em pessoas com mais de 65 anos, principalmente em países desenvolvidos (FABRE *et al*., 2022).

A DMRI se caracteriza como uma doença ocular degenerativa que afeta a mácula, provocando a perda progressiva da visão central. A mácula está localizada na região central da retina, sendo responsável pela visão nítida, percepção de detalhes finos e cores, permitindo atividades como leitura, reconhecimento de rostos e direção (NATIONAL EYE INSTITUTE., 2021**).** A DRMI se divide em dois tipos: a forma seca (atrófica) e a forma úmida (exsudativa). A seca corresponde à forma mais comum e leve da doença, representando cerca de 90% dos casos e ocorre devido ao acúmulo de drusas na região central da retina. As drusas são depósitos lipídicos que se formam entre a retina e a membrana de Bruch. Esses depósitos podem interferir na nutrição da retina e, com o tempo, levar à degeneração das células fotorreceptoras. A úmida, por outro lado, representa a forma mais grave da doença e acomete aproximadamente 10% dos casos. Nessa forma, ocorre o crescimento anômalo de vasos sanguíneos sob a retina, que podem extravasar fluidos ou sangue e causar cicatrizes (BELLO *et al.*, 2002).

Estudos realizados nos últimos 20 anos, revelam que doenças oculares como por exemplo, catarata, glaucoma, degeneração macular, retinopatia diabética, tracoma e erro refrativo não corrigido, são as causas mais comuns de perda severa da visão e cegueira mundialmente (BOURNE *et al.*, 2013). A DMRI representa 8,7% desse total, ficando logo atrás da catarata e do erro refrativo não corrigido (HUANG *et al*, 2024). No Brasil, entre 1,5 e 2 milhões de indivíduos são afetados pela doença. A incidência da doença aumenta significativamente conforme o avanço da idade da população, enquanto apenas 2% das pessoas entre 50-59 anos são afetadas, essa porcentagem pode alcançar 15-20% na faixa etária de 70-79 anos, chegando a aproximadamente 30% em pessoas com 80 anos ou mais (FLAXMAN *et al*., 2017). Considerando o aumento da expectativa de vida e o envelhecimento da população mundial, estimativas apontam que o número de pessoas

acometidas pela DMRI deve aumentar de 196 milhões em 2020 para 288 milhões em 2040 (HUANG *et al*., 2024).

O processamento digital de imagens atua como uma ferramenta indispensável em diversas áreas, especialmente na saúde. Sua aplicação possibilita realçar detalhes, regiões e a qualidade das imagens de fundo de olho. Tornando mais simples e precisa a análise das características das doenças pelos profissionais responsáveis (GONZALES, 2010).

O diagnóstico da DMRI pode ser realizado principalmente através de exames de fundo de olho com as pupilas dilatadas (PARANHOS *et al*,. 2013). Atualmente, existem diversos tipos de exame de fundo de olho, por exemplo: Oftalmoscopia Direta ou Indireta, Retinografia, Tomografia de Coerência Óptica (OCT), Angiografia, entre outros ("RETINA INTERNATIONAL", 2021).

Dentre esses exames, a retinografia consiste em um dos exames mais comuns para identificar a DMRI, pois auxilia na prevenção e diagnóstico precoce da doença em maior escala, devido à sua acessibilidade, ampla disponibilidade, não ser invasivo, ser realizado de forma rápida e ser indolor. A retinografia, também gera imagens coloridas de alta resolução das estruturas do fundo do olho, como a retina, a mácula e os vasos sanguíneos. Dessa forma, fica mais fácil realizar o acompanhamento do quadro do paciente e monitorar a evolução das condições (INTERLENGHI *et al*., 2023; GOBIRA, 2024).

As imagens são analisadas por médicos especialistas que observam a retina e a mácula, à procura de alterações características da doença, como por exemplo a presença de drusas amarelas ou brancas, mudanças na coloração do Epitélio Pigmentar da Retina (EPR), áreas com atrofia muscular e hemorragias (WONG *et al.*, 2014). No entanto, a análise das imagens e identificação da DMRI, pode ser desafiadora, pois, a patologia apresenta alterações que em muitos casos se assemelha às de outras doenças oculares, como glaucoma e retinopatia diabética, o que pode levar a erros e consequentemente resultar em falsos positivos ou negativos. Para evitar situações como estas o profissional precisa ter experiência e um olhar apto para identificação das patologias de forma específica (MUCHUCHUTI *et al*., 2023; MORANO *et al*., 2022).

Além disso, durante e após a realização do exame podem ocorrer vários problemas que irão afetar a qualidade e a precisão do diagnóstico, sendo alguns desses: Possível dilação inadequada da pupila, opacidades nos meios oculares, posicionamento inadequado do paciente ou do aparelho, reflexos de luz, podendo gerar iluminação indesejada na imagem e a subjetividade na interpretação dos especialista, podendo ocorrer diferentes interpretações para um mesmo exame do fundo de olho (MUCHUCHUTI *et al*., 2023 ; MORANO *et al*., 2022).

Outra dificuldade no diagnóstico por retinografia colorida, ocorre quando as imagens são geradas sem nenhum tipo de tratamento, apresentando ruídos que dificultam a visualização de pequenos detalhes. Essa limitação pode afetar a precisão do diagnóstico, prejudicando a identificação de alterações sutis na imagem (GONZALEZ, 2010).

Com base no apresentado acima, este trabalho tem como objetivo realizar a extração das drusas, presentes na retina e mácula, utilizando técnicas básicas de processamento de imagens em retinografias coloridas, com o propósito de auxiliar os especialistas na visualização da região. Tornando o processo de análise das imagens de retinografia e identificação da (DMRI) mais rápido, preciso eficaz.

1.1 OBJETIVOS

1.1.1 OBJETIVOS GERAL

Desenvolver um algoritmo computacional para realizar a segmentação automática das drusas, localizadas na região central da retina (mácula), em retinografias coloridas, a partir de técnicas básicas de processamento digital de imagens.

1.1.2 OBJETIVOS ESPECÍFICO

1. Estudar e compreender sobre a doença Degeneração Macular Relacionada à Idade (DMRI) e realizar um levantamento bibliográfico sobre as características das drusas (formato, intensidade e localização);
2. Entender os elementos técnicos sobre os exames do Fundo de Olho;
3. Selecionar a base de dados;
4. Criar uma estratégia de desenvolvimento da segmentação;

5. Extrair as características na região de interesse;
6. Realizar teste da estratégia nas imagens da base de dados;
7. Comparar os resultados obtidos com os resultados de outros trabalhos;

1.2 ESTADO DA ARTE

Kim e Kim (2018), propuseram um método automático de detecção de drusas em imagens do fundo de olho, com o objetivo de ajudar no diagnóstico clínico da degeneração macular. Os autores optaram pela utilização das seguintes técnicas: extração do canal verde, rotulação dos *pixels* de maior intensidade, aplicação do filtro da mediana, extração da região de interesse (ROI), representada pela área macular, segmentação pelo método de crescimento de regiões e entropia de Renyi. De acordo com os autores, a região macular foi considerada a mais importante pelos médicos e especialistas para identificar a degeneração macular, pois, quanto maior a quantidade de drusas próximas à região central da retina, maior será o impacto na acuidade visual do indivíduo. Os resultados alcançados mostraram uma porcentagem de 93.37% de acerto.

Monteiro e Sarmento (2020), apresentaram um método de detecção e quantificação de drusas em imagens do fundo de olho, utilizando um sistema embarcado HW/SW (*Hardware/Software*) com processadores de baixa potência e baixo custo computacional, para dar suporte aos médicos e especialistas no diagnóstico e monitoramento da DMRI. Aplicaram as seguintes técnicas: extração do canal verde, equalização de histograma adaptável limitada por contraste (CLAHE), segmentação por método de Otsu, rotulação dos componentes conectados e detecção de bordas por Canny. Obteve uma porcentagem de 96.79% de acurácia.

Waseem *et al*. (2014), desenvolveram um sistema automático para a detecção de drusas moles e drusas duras em imagens coloridas do fundo de olho. Os pesquisadores utilizaram técnicas de correção de iluminação, eliminação dos *pixels* do fundo da imagem, aprimoramento do contraste, extração do canal verde, filtro Gabor, classificação através do classificador *K-Nearest Neighbors* (KNN) para detectar regiões de drusas e extração do disco óptico. O sistema mostrou 96% de acurácia, 96% de sensibilidade e 97% especificidade.

Khalid *et al*. (2020), forneceram uma abordagem para auxiliar no diagnóstico automatizado da região afetada pela DMRI em imagens do fundo de olho, visando maior

precisão na identificação precoce da doença. O método utilizou um conjunto de características das drusas, como textura, cor, formato e estrutura, pois, a partir delas foi possível distinguir drusas de exsudatos. Nesse estudo, os pesquisadores realizaram a segmentação do fundo da imagem, remoção de ruídos, localização do Disco Óptico (DO), segmentação dos vasos sanguíneos, detecção e extração das características da mácula. Para isso, aplicaram técnicas como abertura morfológica, Histograma de Gradientes Orientados (HOG), método de Otsu, canal HSI (Matriz, Saturação, Intensidade) e para classificação o classificador máquinas de vetores de suporte (do inglês *Support Vector Machine*), pois, tem alta precisão. Os resultados mostraram 95,45% de precisão ao ser aplicado no conjunto de dados STARE.

Fang *et al*. (2022), lançaram o desafio de Detecção Automática da Degeneração Macular Relacionada à Idade (ADAM) em um conjunto de 1200 imagens do fundo de olho, com o objetivo de criar uma estrutura uniforme de avaliação, permitindo comparações justas entre diferentes modelos desenvolvidos. O desafio ADAM foi realizado no Simpósio Internacional de Imagem Biomédica (ISBI) em 2020 e aconteceu em quatro tarefas, sendo elas: classificação da DMRI, detecção e segmentação do disco óptico, localização da fóvea, detecção e segmentação das lesões (drusas, exsudato, hemorragia e cicatriz). Os pesquisadores analisaram e compararam o desempenho das equipes participantes em cada tarefa realizada. Os resultados foram promissores nas tarefas de segmentação do disco óptico, localização da fóvea e classificação da DMRI. Além disso, foi observado que o uso da estratégia por várias equipes contribui para a melhoria do desempenho, devido à integração de diferentes modelos.

Mittal e Kumari (2015), propuseram um sistema automatizado para detectar bordas e segmentar drusas utilizando imagens do fundo de retina, visando contribuir para o diagnóstico precoce da DMRI, especialmente em atendimentos remotos, através da telemedicina, para residentes de áreas rurais. No método foi aplicado técnicas de extração do canal verde, filtros homomórficos e gaussiano, gradiente, supressão não máxima, rotulação dos componentes conectados, processamento morfológico e detecção de bordas por Canny. Os resultados demonstraram que o sistema obteve 96,40% de precisão no reconhecimento correto das drusas e conseguiu categorizar as drusas em pequenas, intermediárias e grandes com precisão de 88,46, 98,55 e 88,37%, respectivamente.

Yellapragada *et al*. (2021), treinaram uma rede neural de aprendizado profundo com Discriminação de Instância Não Paramétrica (NPID) auto supervisionada, utilizando imagens de fundo de olho não rotuladas e esquemas de classificação de 2, 4 e 9 etapas com um classificador supervisionado, permitindo a classificação da gravidade da DMRI em diferentes escalas. Os autores mapearam o tamanho, área, tipo de drusas, área de despigmentação ou hiperpigmentação e presença de atrofia geográfica, que são características da DMRI para contribuir com o aprendizado auto supervisionado. Além disso, as imagens foram pré-processadas com filtro Laplaciano e filtro de Gauss. A rede neural alcançou resultados comparáveis com as redes treinadas supervisionadas e com a análise dos médicos e especialistas, na classificação da DMRI avançada (82% vs. 81-92% ou 89%) e DMRI intermediária (87% vs. 90-92% ou 96%).

1.3 ORGANIZAÇÃO DO TRABALHO

Esse trabalho está dividido em 6 seções: a seção 1 envolve uma breve introdução referente ao tema, a problemática, a justificativa do trabalho, os objetivos gerais e específicos. A seção 2 oferece uma explicação sobre o olho humano e sua anatomia, com ênfase na estrutura e função da retina, citando doenças oculares associadas à retina, como a DMRI. Esta seção também explora em detalhe as causas dessa patologia, suas classificações, sintomas, métodos de diagnósticos, com foco no diagnóstico por retinografia colorida e tratamento. A seção 3 aborda a teoria das técnicas de processamento digital de imagens utilizadas. Na seção 4 descreve o sistema desenvolvido, apresentando a estratégia escolhida e mostrando os resultados em cada etapa. A seção 5 exibe os resultados obtidos. Por fim, a seção 6 apresenta a conclusão e as perspectivas de trabalhos futuros.

2. O OLHO

O olho, também conhecido como globo ocular ou bulbo ocular, está localizado em um compartimento ósseo do crânio, denominado cavidade orbitária ou órbita ocular. As paredes da órbita protegem os olhos contra possíveis lesões e permitem um posicionamento mais preciso do eixo visual, pois, fornecem pontos de apoio para os músculos extraoculares (STANDRING, 2015).

O globo ocular tem aproximadamente 3 cm de diâmetro, ocupando apenas um quinto do espaço da órbita ocular. O restante da cavidade está preenchido pelos músculos extraoculares, vasos e nervos que são sustentados pela gordura orbital e tecido conjuntivo (STANDRING, 2015).

O olho funciona como um órgão fotossensível, responsável pela percepção visual, detecção de objetos, visualização das cores, captura e conversão da luz, resultando na formação de imagens no cérebro, permitindo a visão (RODRIGUES, 2016; BEAR *et al*., 2017).

Embora seja pequeno, o olho representa um dos órgãos mais complexos do corpo, sendo constituído por diversas estruturas responsáveis pelo suporte, proteção, movimentação e processamento da imagem. Essas estruturas incluem, músculos, pálpebras, cílios, conjuntiva, corpo ciliar, córnea, cristalino, íris, pupila, humor aquoso, humor vítreo, esclera, nervo óptico e retina (NASCIMENTO JÚNIOR, 2020). Como podem ser observadas nas (Figura 1(a)) e (Figura 1(b)).

Figura 1: Anatomia do olho humano: (a) olho em secção transversal e (b) olho em visão geral.

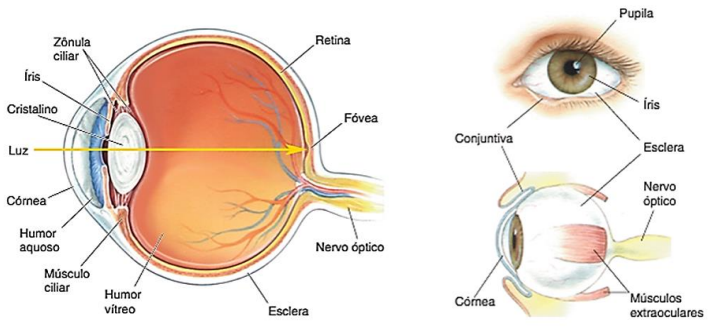

(a) (b)

Fonte: Adaptado de (BEAR *et al*., 2017).

A formação da imagem inicia quando a luz incide no olho, pelos raios que são emitidos ou refletidos por objetos no ambiente. Essa luz passa pela córnea, humor aquoso, pupila, cristalino e humor vítreo, até ser focada na retina. Na retina, os fotorreceptores (bastonetes e cones) convertem a luz em sinais elétricos e o nervo óptico os envia ao cérebro. Por fim, o cérebro processa esses sinais e forma a imagem. A focalização dos objetos se dá pela combinação da refração da córnea e do cristalino, que ajusta seu formato para focar de forma correta sobre a retina (BEAR *et al*., 2017; RODRIGUES, 2016).

2.1 RETINA

A retina consiste em uma camada fina de células fotorreceptoras e células gliais, localizada na parte interna e posterior do olho. Desempenha um papel essencial na visão, sendo responsável por captar a luz (fótons), convertê-la em sinais elétricos e transmiti-los para o cérebro ao longo das vias neurais, onde esses sinais são processados, resultando na formação de imagens (NGUYEN *et al*., 2020).

Existem dez camadas na retina, sendo elas a membrana pigmentar, camada de bastonetes e cones, camada nuclear externa, camada plexiforme externa, camada nuclear interna, camada plexiforme interna, camada ganglionar, camada de fibras e nervo óptico e camada limitante interna (Figura 2). Além disso, os neurônios da retina são divididos em cinco tipos, os fotorreceptores, as células bipolares, as células amácrinas, as células horizontais e as células ganglionares (HALL, 2011).

Figura 2: Anatomia e organização das camadas da retina.

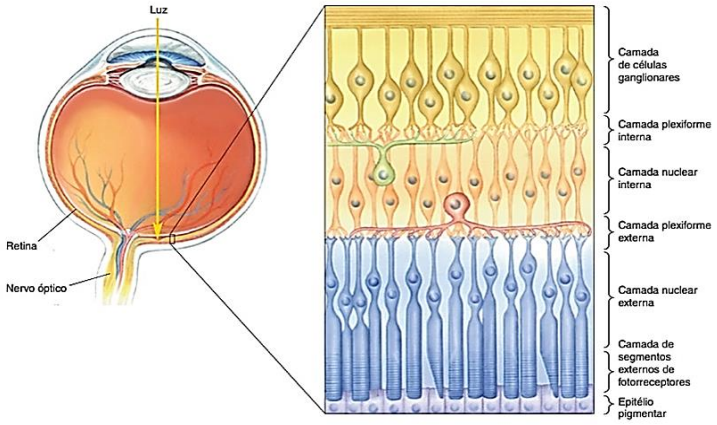

Fonte: Adaptado de (BEAR *et al*., 2017).

Os fotorreceptores da retina são divididos em dois tipos, os bastonetes e os cones, os dois são nomeados pelo seu formato e pela sua aparência em geral. Os bastonetes, são altamente sensíveis à luz fraca (visão escotópica) e estão concentrados nas regiões periféricas da retina. Essas células são responsáveis por detectar baixos níveis de luminosidade, tornando-as essenciais para a visão em condições de pouca luz e para a visão periférica, permitindo a detecção de objetos fora do campo central de visão. Por outro lado, os cones, mais sensíveis à luz do dia (visão fotópica), estão localizados na parte central da retina, na fóvea. Os cones são responsáveis pela visão diurna e pela visão em cores. Existem três tipos de cones, cada um sensível a diferentes comprimentos de onda de luz: vermelho, verde e azul. A combinação da ativação desses cones permite distinguirmos uma ampla gama de cores. (HALL, 2011; NGUYEN *et al*., 2020).

No centro da retina, na parte posterior do olho, existe uma região circular de 5.5 mm de diâmetro, com tonalidade mais escura e com aspecto amarelado, representada pela mácula, também conhecida como mácula lútea (Figura 3). A mácula compõe a área mais sensível da retina, sendo responsável pela visão central e pela capacidade de enxergar detalhes com clareza, permitindo atividades como leitura, escrita e a capacidade de reconhecer rostos e objetos com precisão. A fóvea está localizada no centro da mácula e corresponde à área de maior acuidade visual, pois, contém uma alta concentração de cones (BEAR *et al*., 2017; NGUYEN *et al*., 2020; DENG *et al*., 2021).

Figura 3: Vista da parede posterior do olho a partir de um oftalmoscópio.

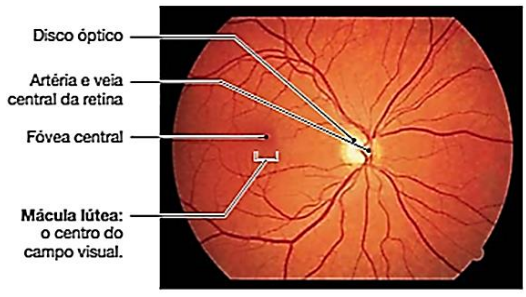

Fonte: Adaptado de **(**SILVERTHORN, 2017)**.**

Apesar dos grandes avanços da medicina nas últimas décadas, ainda existem muitas patologias relacionadas à retina que não têm cura. Quando não tratadas de forma correta, podem levar a cegueira irrecuperável. Algumas dessas doenças são: retinopatia diabética, glaucoma, descolamento da retina, degeneração macular relacionada à idade e retinose pigmentar (MEIRELLES, 2019; NGUYEN *et al*., 2020).

A próxima seção descreve a Degeneração Macular Relacionada à Idade (DMRI), doença selecionada para realizar a análise neste trabalho.

2.2 DEGENERAÇÃO MACULAR RELACIONADA À IDADE (DMRI)

A fisiopatologia da Degeneração Macular Relacionada à Idade (DMRI) engloba a degeneração progressiva da região da mácula, área responsável pela visão central e pela capacidade de enxergar detalhes com clareza. Essa patologia caracteriza alterações que afetam além da mácula, as camadas neurais da retina, o epitélio pigmentar da retina (EPR), membrana de Bruch (BrM) e coróide, resultando na perda gradual da visão central. A DMRI representa uma das principais causas de perda severa da visão e cegueira em pessoas com mais de 65 anos (MINISTÉRIO DA SAÚDE, 2022; NGUYEN *et al.*, 2020; COHEN *et al*., 2024).

Existe dois tipos de DMRI: a seca, também denominada atrófica, que constitui a forma mais comum e menos agressiva da doença, responsável por 80 a 85% dos casos, e a úmida, conhecida como exsudativa ou neovascular, que representa a forma mais agressiva da doença, presente em 15 a 20% dos casos, sendo responsável por aproximadamente 90% dos casos de perda visual severa, relacionados à doença (MINISTÉRIO DA SAÚDE, 2022).

A forma seca da doença, começa com a redução da eficiência do epitélio pigmentar da retina (EPR), camada fundamental para a remoção dos resíduos metabólicos gerados pelos fotorreceptores. Com o passar dos anos e o avanço da idade, ocorre o acúmulo de materiais lipídicos e protéicos entre o epitélio pigmentar da retina e a membrana de Bruch, tornando a membrana gradualmente mais espessa. O que acaba prejudicando as trocas de nutrientes e gera resíduos entre a retina e a coriocapilar, provocando alterações que afetam a nutrição e integridade das células da retina. Esses depósitos são chamados de drusas, estruturas amareladas visíveis durante o exame oftalmológico (DUARTE, 2010; TORRES *et al*., 2021; MINISTÉRIO DA SAÚDE, 2022; PINA *et al.,* 2022).

O aparecimento das drusas representa um marco da forma seca da DMRI. Além disso, ocorre a redução progressiva da acuidade visual e formação de áreas de atrofia na retina, conhecidas como atrofia geográfica que comprometem a visão central. A perda de

visão ocorre de forma lenta, mas progressiva (TORRES *et al*., 2021; MINISTÉRIO DA SAÚDE, 2022; PINA *et al.,* 2022).

Na forma seca, as drusas podem ser classificadas em dois grupos principais, de acordo com suas características e implicações clínicas. As drusas duras (Figura 4(a)), são pequenas e puntiformes, apresentam coloração amarelada, têm bordas bem definidas e contornos regulares. Podem ser visualizadas em indivíduos idosos e saudáveis, pois, não necessariamente constituem a DMR e raramente coalescem. Caso apareçam em grande quantidade, pode indicar maior risco de desenvolvimento da doença. E por fim as drusas moles (Figura 4(b)), que são maiores e mais difusas em comparação com as duras, apresentam coloração branco - amarelada e têm bordas mal definidas. Essas drusas possuem composição similar à das duras, mas com maior concentração de lipídios, conferindo menos homogeneidade. Sua presença torna mais suscetível a evolução da DMRI para formas mais graves, como atrofia geográfica ou para a forma úmida da doença (RÊGO, 2012; SODRÉ, 2019).

Figura 4: Classificação das drusas na forma seca. (a) drusas duras (b) drusas moles.

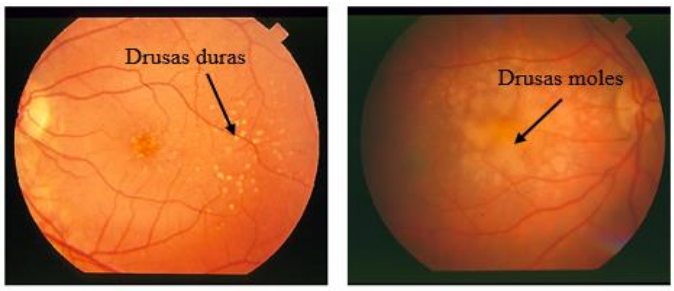

(a) (b)

Fonte: Adaptado da base de dados.

A DMRI úmida tem como principal característica a formação de vasos sanguíneos anormais sobre a retina, chamada de neovascularização. Esses vasos crescem devido ao acúmulo de material entre a retina e a membrana de Bruch (forma seca da doença), resultando em falhas na barreira entre a retina e a coroide. Além disso, são frágeis e propensos a vazamentos, o que leva ao acúmulo de fluidos e sangramento na região da mácula, causando o edema macular e consequentemente levando à formação de cicatrizes no tecido retiniano e afetando de forma irreversível visão a central do indivíduo (Figura 5) (MINISTÉRIO DA SAÚDE, 2022; PINA *et al.,* 2022).

Figura 5: Indícios de DMRI exsudativa: (a) neovascularização como área cinza-esverdeada subfoveal, (b) depósito de lipídeos de forma densa, (c) hemorragia intra e sub-retiniana e (d) cicatriz disciforme.

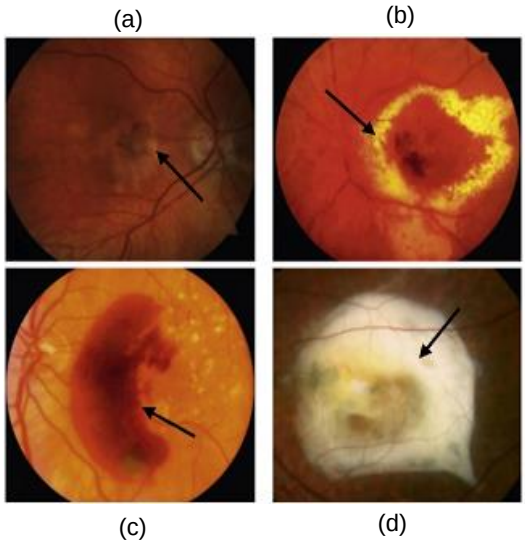

Fonte: Adaptado de (BOWLING, 2022).

2.2.1 CLASSIFICAÇÃO DOS ESTÁGIOS DE PROGRESSÃO

De acordo com a escala de gravidade do *Age-Related Eye Disease Study* (AREDS), a DMRI pode ser classificada em quatro categorias e está exemplificada na Figura 6 (CARVALHO *et al*., 2023; MINISTÉRIO DA SAÚDE, 2022), sendo elas:

- Categoria 1 (sem DMRI): caracterizada por poucas drusas pequenas (<63µm de diâmetro) ou nenhuma.

- Categoria 2 (DMRI em estágio inicial): determinada como uma combinação de várias drusas pequenas, algumas drusas intermediárias (63 a 124µm de diâmetro) em um ou ambos os olhos, ou modificações do epitélio pigmentar da retina (EPR).

- Categoria 3 (DMRI intermediária): definida por drusas intermediárias extensas, pelo menos uma drusa grande (=>125µm de diâmetro) em ambos os olhos, ou atrofia geográfica não incluindo o centro da fóvea.

- Categoria 4 (DMRI avançada ou tardia): ocorre em apenas um olho. Inclui a atrofia geográfica do EPR e coriocapilares englobando o centro da fóvea, a neovascularização, descolamento seroso e/ou hemorrágico da retina sensorial ou

do EPR, exsudatos lipídicos, extravasamento vascular, proliferação fibrovascular sub-retiniana ou sub-EPR e cicatriz disciforme.

Figura 6: Classificação dos estágios de progressão das drusas. (a) sem DMRI, (b) DMRI em estágio inicial, (c) DMRI intermediária, (d) DMRI avançada.

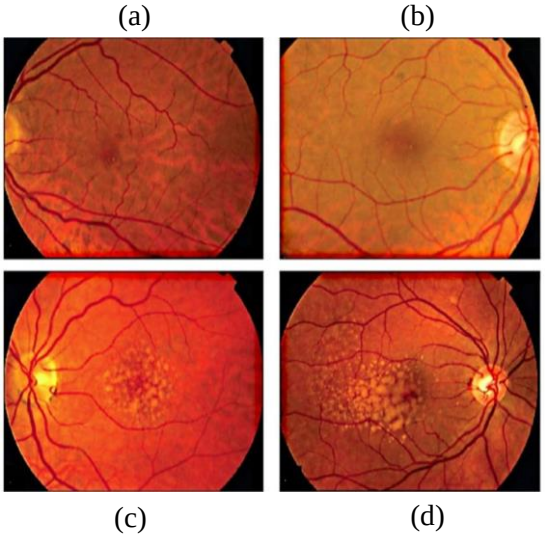

Fonte: Adaptado de (CARVALHO *et al*., 2023).

2.2.2 DIAGNÓSTICO POR IMAGEM

O diagnóstico da DMRI tem como base uma combinação de exame clínico, com testes funcionais e exames de imagem, para avaliar as modificações estruturais presentes na retina. Inicialmente o médico investiga sintomas como visão central embaçada, dificuldade para enxergar em ambientes com baixa iluminação e manchas escuras no campo visual. A avaliação envolve o teste de acuidade visual, Grade de Amsler e o exame do fundo de olho, oftalmoscopia, possibilitando detectar irregularidades, como a existência de drusas, regiões de atrofia macular e alterações no (EPR) ou neovascularização (MINISTÉRIO DA SAÚDE, 2022; PINA *et al.,* 2022).

Os exames de imagem são importantes para confirmação do diagnóstico, localização das lesões, acompanhamento e monitoramento da evolução das condições do paciente, auxiliando os médicos e especialistas. Os exames mais utilizados são Tomografia de Coerência Óptica (OCT), Angiografia por Fluoresceína (FA), Tomografia de Coerência Óptica (OCTA), Angiografia com verde de indocianina, Retinografia e Ultrassonografia ocular. (MINISTÉRIO DA SAÚDE, 2022; PINA *et al.,* 2022).

A próxima seção descreve o diagnóstico por imagem usando retinografia colorida, método selecionado para realizar a análise do trabalho.

2.2.2.1 RETINOGRAFIA COLORIDA

O diagnóstico por retinografia colorida, permite capturar fotografias detalhadas das estruturas da retina, como os nervos ópticos, vasos sanguíneos, mácula, fóvea, disco óptico, entre outras. Esse exame permite identificar alterações patológicas nas estruturas do olho, ajudando a detectar diversas doenças como o glaucoma, retinopatia diabética e degeneração macular. O exame permite realizar o acompanhamento diagnóstico precoce da doença, garantindo assim um tratamento adequado. (MINISTÉRIO DA SAÚDE, 2022; LANDRY, 2016).

No século XIX a oftalmoscopia foi desenvolvida por Hermann Von Helmholtz, permitindo pela primeira vez na história a criação de um método capaz de ver diretamente as estruturas internas do olho. Alguns anos depois, com a descoberta da fotografia, os cientistas encontraram meios de capturar imagens da retina, primeiramente em preto e branco. Somente nas décadas de 1950 e 1960 que as inovações tecnológicas possibilitaram a captura de imagens coloridas da retina em alta resolução, dando assim vida à retinografia colorida. Com o avanço da tecnologia em imagens digitais, no século XXI a retinografia deu mais um salto no desenvolvimento, podendo agora armazenar imagens para análises em longo prazo, melhorando precisão do diagnóstico, eficiência no tratamento das doenças oculares e principalmente permitindo o acompanhamento e evolução das alterações na retina através das imagens (KASHANI *et al.*, 2021; SAINE, 1996; LANDRY, 2016).

Para a realização da retinografia colorida o técnico utiliza um equipamento denominado retinógrafo (Figura 7), responsável por capturar imagens de fundo do olho, com alta resolução e de forma detalhada. Os principais componentes do retinógrafo são: o sistema óptico, conjunto de lentes cuja função consiste em focalizar a retina de forma eficaz, além de possuir uma fonte de luz que normalmente pode ser composta por LEDs ou lâmpadas xenon, iluminando assim a retina do paciente de maneira adequada sem causar desconforto. A câmera digital de alta resolução captura as imagens da retina em alta definição, sendo capaz de registrar detalhes finos e consequentemente ajudar a melhorar a precisão da análise do diagnóstico de doenças oculares. Além desses, tem o sistema de controle e processamento de imagens, onde os retinógrafos são conectados aos

computadores que processam os dados obtidos pela câmera, possibilitando a otimização dos arquivos e aplicação de ajustes no contraste e no brilho. Tornando possível enviar as imagens que foram processadas para análise em tempo real (KASHANI *et al.*, 2021; LANDRY, 2016).

Figura 7: Retinógrafo convencional.

Fonte: Adaptado de (ALVES, 2024).

Vale ressaltar que alguns retinógrafos mais avançados, podem ficar acoplados a fluoresceinografia ou angiografia por tomografia de coerência óptica (OCT), possibilitando a obtenção de imagens detalhadas dos vasos sanguíneos da retina (ELLIOTT, 2020).

O exame de retinografia colorida se dá em quatro etapas, sendo estas etapas simples, rápidas e não invasivas. Na primeira etapa acontece a preparação do paciente, aplicando colírios dilatadores, com o objetivo de ampliar as pupilas, permitindo melhor visualização da retina, normalmente esse processo leva de 15 a 20 minutos. Após isso, temos a segunda etapa, em que o paciente fica posicionado em frente ao retinógrafo com sua cabeça e queixo apoiados (Figura 8), para evitar movimentação e garantir uma imagem mais precisa do fundo do olho. A terceira etapa, de captura da imagem, onde um oftalmologista ou um técnico especializado, instrui o paciente a olhar fixamente em um ponto no retinógrafo, para que a câmera capture as imagens adequadamente, podendo ser realizado de diferentes ângulos para obter dados mais completos da retina e das estruturas oculares. Por fim, a quarta etapa, onde ocorre a geração da imagem para futuras análises (Figura 9). Dependendo da condição do paciente e da qualidade da imagem gerada, pode ser necessário repetir o exame, para que o técnico ou especialista ajuste a intensidade da luz ou a posição do paciente (ELLIOTT, 2020).

Figura 8: Posicionamento do paciente frente retinógrafo (Manual de Treinamento de Aquisição de Retinografia – Projeto ELSA, 2009).

Fonte: Adaptado de (GUTTERRES, 2010).

Para salvar as imagens obtidas durante o exame, a câmera de alta resolução do retinógrafo captura a reflexão da luz pela retina, processa essa informação e converte esses dados em uma imagem digital (Figura 9). Essa imagem segue para um *software* oftalmológico por meio de um computador que está conectado ao retinógrafo. Tornando possível aplicar otimizações na imagem, como ajuste de brilho e contraste, para aprimorar a visualização da estrutura da retina (ZHU, 2022).

Figura 9: Exemplo da retinografia colorida.

Fonte: Adaptado de (STANDRING, 2015).

As fotografias geradas pelo retinógrafo são armazenadas em formatos digitais, como o JPEG (*Joint Photographic Experts Group*), formato frequentemente utilizado em imagens médicas, por conseguir compactar a imagem, equilibrando a qualidade e tamanho do arquivo. O TIFF (*Tagged Image File Format),* pois, não passa por processos de compressão, tendo como objetivo preservar a fotografia, para a imagem ter maior qualidade, sendo mais adequada para arquivamento a longo prazo. Enquanto o DICOM (*Digital Imaging and Communications in Medicine*) vem sendo o padrão internacional

para imagens médicas, devido a possibilidade de armazenar outras informações junto às imagens, como por exemplo informações do paciente podendo ser desde o histórico médico a dados mais simples como nome, idade e data do exame. Além disso, facilita a integração com sistemas de arquivamento e comunicação de imagens médicas (PACS), possibilitando compartilhamento seguro de imagens entre diferentes sistemas e hospitais (JAN, 2019; LANDRY, 2016).

3. PROCESSAMENTO DIGITAL DE IMAGENS

3.1 CONTEXTUALIZAÇÃO HISTÓRICA

O desenvolvimento do sistema Bartlane, no século passado, marcou o início do processamento de imagens. Esse sistema realizava a transmissão de imagens através de cabos submarinos entre Londres e Nova York, com o objetivo de reduzir o tempo de envio das fotografias. Inicialmente as fotografias eram codificadas com apenas cinco níveis de intensidade, resultando em imagens com pouca variação tonal. Alguns anos depois, a codificação foi aumentada para quinze níveis de intensidade, gerando assim mais variações de brilho e proporcionando uma melhor qualidade visual, com mais detalhes perceptíveis (MARQUES *et al*., 1999).

Na década de 1960 ocorreu um grande avanço no processamento de imagens, devido ao surgimento dos primeiros computadores com capacidade de processar grandes volumes de dados visuais. Assim, organizações como a Administração Nacional de Aeronáutica e Espaço (NASA) utilizaram *softwares* para melhorar as fotografias obtidas por satélites. Um exemplo disso foi o aprimoramento de imagens lunares pela sonda Ranger7 em 1964, que removeu ruídos e destacou detalhes na imagem, sendo um marco tanto na exploração espacial quanto na área médica (GONZALEZ, 2010).

Com o avanço da tecnologia na década de 1980 e 1990, o processamento de imagens alcançou novas melhorias e expandiu para áreas como a medicina, geologia, astronomia, entre outros. A aplicação de algoritmos matemáticos, como a transformada de Fourier e outras técnicas, desempenhou papel essencial na melhora de imagens médicas de raio-x e tomografias. Esse progresso impactou não só o campo médico, mas também o monitoramento ambiental e previsão do tempo, através de imagens de satélite. A ampliação da capacidade computacional, possibilitou o uso de algoritmos mais sofisticados para tarefas como, segmentação, realce e reconstrução de imagens, promovendo assim inovações como a restauração de imagens antigas, controle de qualidade em indústrias, aplicações em robótica e veículos autônomos. (GONZALEZ, 2010; MARQUES *et al*., 1999).

Ao incorporar inovações tecnológicas, como inteligência artificial e aprendizado de máquina, no início do século XXI, o processamento de imagens apresentou avanço significativo. O desenvolvimento de câmeras digitais e *smartphones* impulsionou o

desenvolvimento e aplicação de algoritmos cada vez mais sofisticados, capazes de aprimorar imagens e reconhecer padrões de forma automática. Um exemplo marcante dessa evolução são as redes neurais convolucionais, que revolucionaram o campo, especialmente no reconhecimento facial, proporcionando avanços expressivos em precisão e eficiência (GONZALEZ, 2010).

O Processamento e Análise Digital de Imagens (PADI) utiliza algoritmos e técnicas para manipular, melhorar e extrair informações importantes de imagens digitais, tendo como objetivo transformar dados visuais em informações que podem ser utilizadas, para diagnóstico médico, reconhecimento facial, entre outras. Existem duas técnicas principais, o Processamento Digital de Imagens (PDI), onde as imagens são tratadas, aprimorando sua qualidade e características e a Análise Digital de Imagens (ADI), que envolve a análise e extração de informações relevantes para interpretar conteúdos, reconhecer objetos e identificar padrões. O fluxograma (Figura 10), representa os dois processos (GONZALEZ, 2010).

Figura 10: Fluxograma dos processos de PDI e ADI.

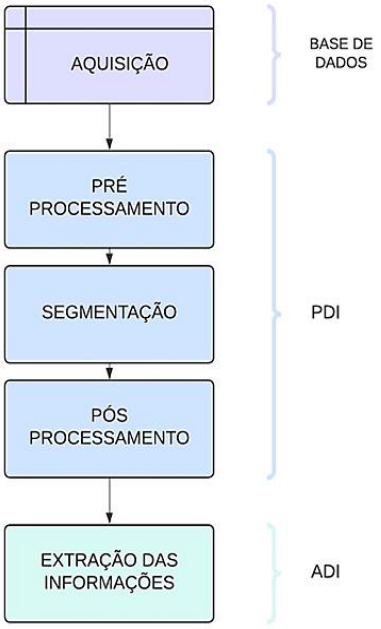

Fonte: Autoria própria.

O processamento computacional de imagens pode ser classificado em três tipos: nível baixo, médio e alto. O nível baixo corresponde ao pré-processamento, envolvendo operações simples com o objetivo de aprimorar a qualidade da imagem, como redução de ruído, ajustes de tamanho e realces de contraste. No nível médio ocorre a extração de características das imagens, por meio de técnicas de segmentação, pois, fornecem informações sobre bordas, texturas e forma dos objetos que compõem a imagem original. Por fim, o nível alto visa a interpretação dos dados obtidos, utilizando abordagens avançadas, como aprendizado de máquina ou inteligência artificial. Nesse nível as imagens são analisadas para identificar objetos, reconhecer padrões ou realizar classificações (GONZALEZ, 2010).

No Brasil, o processamento de imagens vem sendo bastante utilizado em setores como agricultura, monitoramento ambiental, saúde e segurança. A utilização se dá através de diversas técnicas de processamento de imagem, melhorando brilho, contraste, filtragem e diversos outros parâmetros da imagem. Essas aplicações garantem melhor qualidade visual e aprimoramento nas fotografias que auxiliam no diagnóstico médico mais preciso. Os médicos ainda podem utilizar técnicas mais avançadas de segmentação de imagem, reconstrução 3D e várias outras, logo o processamento de imagens se torna uma ferramenta valiosa para o uso cotidiano nas clínicas (SILVA *et al.,* 2019).

3.2 CONCEITOS FUNDAMENTAIS

As imagens digitais podem ser definidas como uma função bidimensional $f(x, y)$ discretizada, onde x e y representam coordenadas espaciais de cada ponto na matriz, denominado como *pixels,* os quais constituem as menores unidades da imagem. A função f atribui a cada *pixel* um valor correspondente a intensidade ou nível de cinza associados a posição (x, y). Nas imagens coloridas (x, y) consistem em um vetor que armazena os valores de intensidade para cada canal de cor, vermelho (R), verde (G) e azul (B) (QUEIROZ *et al*., 2001; GONZALEZ, 2010).

A formação da imagem digital se dá a partir da conversão de uma imagem analógica, capturada por sensores que detectam a luz e as transformam em sinais elétricos. Esses sinais são convertidos em valores finitos, representando a intensidade de luz, em pontos diferentes da imagem. Os dados são então processados por dispositivos eletrônicos e armazenados digitalmente para visualização e utilização (SCURI, 2002).

Nos próximos tópicos serão abordados os conceitos referentes às técnicas utilizadas na estratégia algorítmica deste trabalho.

3.2.1 TONS DE CINZA

Em uma imagem monocromática, o fator mais importante está na intensidade, sendo essa representada por níveis de cinza, variando do branco ao preto. A luz monocromática, também chamada de luz acromática, indica a falta de mistura de cores, apresentando apenas uma intensidade de luz. Essa intensidade de luz pode ser percebida como uma gama de variações de preto a diferentes tons de cinza, até chegar no branco, a escala de cinza (Figura 11) representa essa variação de intensidade. As imagens compostas por apenas essa variação, são definidas como imagens em níveis de cinza. São muito usadas para processamento digital de imagens e visão computacional, pois, a ausência de cores facilita a análise das características de intensidade da luz (GONZALEZ, 2010).

Figura 11 : Escala de cinza.

Fonte: *Mathworks* 2024.

Para transformar as imagens coloridas (Figura 12(a)) em tons de cinza (Figura 12(b)), aplicam uma fórmula ponderada aos canais de cor da imagem, onde o vermelho (R) recebe 0,2989, o verde (G) adquire 0,5870 e o azul (B) recebe 0,1140. As funções podem calcular a intensidade de cada *pixel* presente na imagem, através da Equação (1) (MathWorks, 2024).

$$Cinza = 0{,}2989 \times R + 0{,}5870 \times G + 0{,}1140 \times B \quad (1)$$

Figura 12: Escala de cinza: (a) imagem original em RGB (b) imagem em níveis de cinza.

Fonte: *Mathworks* 2024.

3.2.2 MODELOS RGB DE CORES

O modelo de cores RGB consiste na combinação de três componentes, onde cada componente do sistema será um canal de cor primária, sendo essas cores, vermelho (Red), verde (Green) e azul (Blue). A imagem colorida resulta da combinação dos valores de intensidades dos três canais e ao ser alimentada a um monitor (Figura 13). Quando representada de forma digital, a cor de um *pixel* contém três valores numéricos que correspondem à intensidade de cada canal de cor. Por exemplo, a cor branca tem valor (255, 255, 255), significando que todos os canais de cor estão na sua intensidade máxima, enquanto o preto pode ser reproduzido por (0, 0, 0), com todos os canais ausentes (GONZALEZ, 2010).

Figura 13: Formação da imagem no modelo RGB.

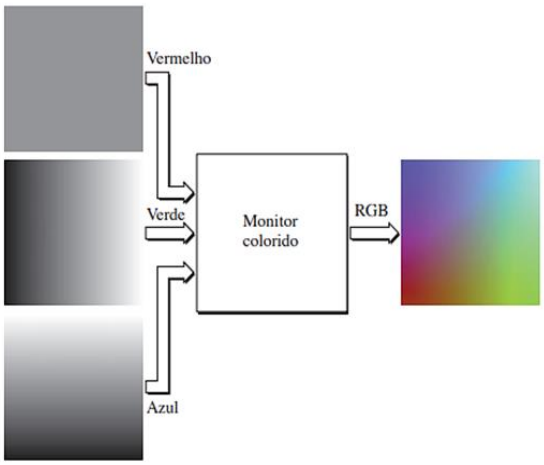

Fonte: Adaptado de (GONZALEZ, 2010).

Cada canal de cor tem intensidades que podem variar de (0 a 255) em uma representação de 8 *bits* (1 *byte* por canal), resultando em 16.777.216 cores possíveis. Com

a combinação de 256 intensidades para cada um dos três canais, formando um vetor 3D. Ou seja, um *pixel* com valores (255, 0, 0) será vermelho, enquanto um *pixel* com valores (0, 255, 0) será verde e um *pixel* com valor (0, 0, 255) será azul. Uma imagem representada nesse modelo, pode ser decomposta em três imagens. Para isso, ocorre a extração de um desses três canais da imagem, isolando um dos valores dos três componentes e definindo os outros canais como zero, tendo como resultado a Figura 14 (GONZALEZ, 2010).

Figura 14: Imagem RGB, (a) canal vermelho da imagem, (b) canal verde da imagem e (c) canal azul da imagem.

Fonte: Adaptado de (GONZALEZ, 2010)

3.2.3 EQUALIZAÇÃO DE HISTOGRAMA

O contraste representa uma propriedade importante no processamento de imagens, pois, equivale à diferença de intensidade e tonalidade mais claras e mais escuras, sendo crucial para determinar a qualidade da imagem, já que quanto maior o contraste, maior a percepção de detalhes. Dessa forma, a diferença entre áreas claras e escuras aumenta e quanto menor for o contraste mais desbotada e sem brilho será, dificultando a visualização de detalhes. Nessas condições, técnicas de realce de imagem se tornam fundamentais para melhorar a qualidade visual e facilitar a interpretação dos detalhes (GONZALEZ, 2010).

Os histogramas constituem a base para diversas técnicas de processamento de imagens, podendo ser utilizado para o realce. Histogramas também contêm informações

relevantes da imagem, sendo bastante úteis em outras aplicações de processamento digitais, como compressão e segmentação. Além disso, são fáceis de serem calculados em um aplicativo computacional, sendo uma função discreta que pode ser representada pela função *h(rk) = nk*, onde o *rk* representa o *k-ésimo* valor de intensidade e o *nk* representa o número de *pixels* na imagem com intensidade de *rk* (GONZALEZ, 2010; SOLOMON *et al*., 2011). A seguir, na (Figura 15) ilustra os histogramas com características de intensidade escura, clara, de baixo e alto contraste.

Figura 15: Imagem e histogramas das imagens, (a) imagem escura, (b) imagem clara, (c) imagem de baixo contraste e (d) imagem de alto contraste.

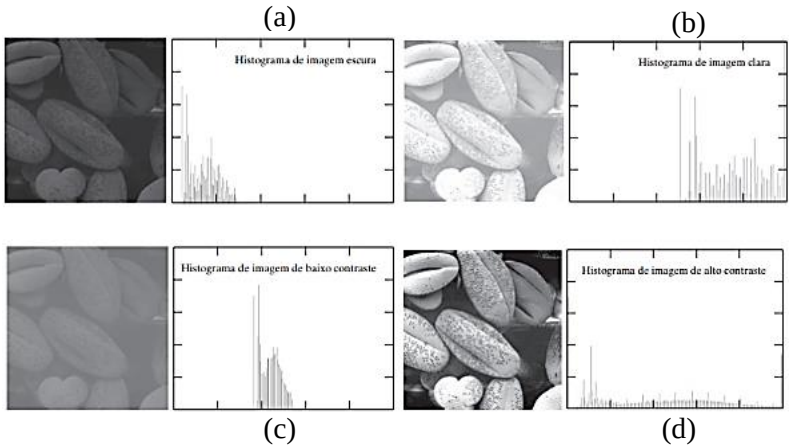

Fonte: Adaptado de (GONZALEZ, 2010).

Uma técnica bastante utilizada denominada de equalização de histograma, permite manipular e distribuir níveis de intensidade de forma a ocuparem uma gama mais elevada de valores, assim aprimorando o contraste. Isso melhora visualmente os níveis de detalhes da imagem, tornando-a uma técnica bastante eficiente (GONZALEZ, 2010).

3.2.4 MORFOLOGIA MATEMÁTICA

A morfologia matemática consiste em um conjunto de técnicas utilizadas para a análise de estruturas e de formas geométricas em uma imagem. Normalmente são aplicadas nas etapas de pré e/ou pós processamento, com o objetivo de manipular e interpretar formas e estruturas contidas em uma imagem binária ou em escala de cinza. Utiliza operações específicas que exploram as propriedades geométricas e topológicas dos objetos (GONZALEZ, 2010).

As operações morfológicas são realizadas entre uma imagem (Figura 16(a)) e um elemento estruturante (EE) (Figura 16(b)), definido como um pequeno conjunto matricial formado por *pixels*, utilizados para examinar uma imagem buscando propriedades de interesse. Após a aplicação da operação, surge uma nova imagem (Figura 16(c)), com as propriedades estruturais dos objetos alteradas de acordo com o tipo da operação realizada. O elemento estruturante tem diversos formatos, como diamante, disco, retângulo, octágono, linha ou quadrado (GONZALEZ, 2010; SOLOMON *et al*., 2011; MathWorks, 2024).

Figura 16: (a) conjunto, (b) elemento estruturante, (c), conjunto preenchido com os elementos de fundo para formar arranjo matricial (d) elemento estruturante no arranjo matricial retangular e (e) conjunto processado com elemento estruturante.

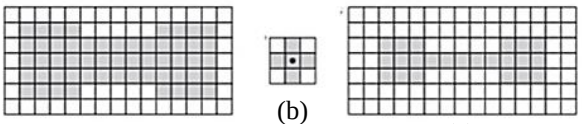

Fonte: Adaptado de (GONZALEZ, 2010).

Existem vários tipos de operações morfológicas no processamento digital de imagens, algumas delas são: erosão, dilatação, abertura, fechamento, gradiente morfológico, *top-hat* e transformação de reconstrução (GONZALEZ, 2010; SOLOMON *et al*., 2011). Neste trabalho, foi utilizado a operação morfológica de abertura.

A operação de abertura, definida por $A \circ B = (A \ominus B) \oplus B$, consiste em uma erosão seguida por uma dilatação, aplicando o mesmo elemento estruturante. Na erosão, denotada por $A \ominus B$, as regiões são reduzidas e pequenos detalhes são eliminados, removendo os *pixels* das bordas (Figura 17(c)). Em seguida, no processamento morfológico de dilatação, representado por *B* $A \oplus B$, as regiões se expandem e pequenos buracos são preenchidos, adicionando *pixels* às bordas (Figura 19(d)) (GONZALEZ, 2010; SOLOMON *et al*., 2011).

Esse processo inclui uma imagem *A* (Figura 17(a)) e um elemento estruturante *B* (Figura 17(b)), permitindo remover pequenos ruídos e suavizar contornos, enquanto mantém a forma original da imagem. A quantidade de *pixels* removidos e adicionados depende do elemento estruturante B criado, como mostra a Figura 17 (GONZALEZ, 2010; SOLOMON *et al*., 2011).

Figura 17: Processamento morfológico de abertura, (a) objeto (b) elemento estruturante e (c) resultado da erosão e d) resultado da abertura.

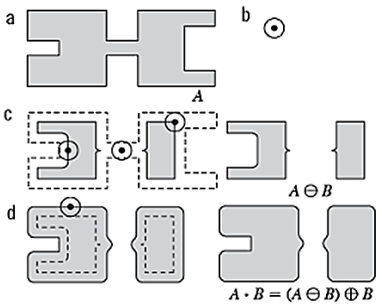

Fonte: Adaptado de (GONZALEZ, 2010).

3.2.5 LIMIARIZAÇÃO

A limiarização por intensidade corresponde a uma técnica de processamento digital de imagens, utilizada para segmentar ou dividir uma imagem em regiões distintas, de acordo com os níveis de intensidade ou brilho dos *pixels*. Essa técnica tem como objetivo principal transformar uma imagem em escala de cinza em uma imagem binária, destacando objetos e regiões de interesse. Para isso, precisa definir um limiar de intensidade, onde cada *pixel* da imagem será comparado a esse valor. Aqueles com intensidade inferior ao limiar estabelecido são colocados valor 0 (preto), enquanto os de intensidade superior, recebem o valor 1 (branco), como ilustrado na Figura 18.

Existem vários tipos de limiarização, como adaptativa, onde a limiarização varia dependendo das coordenadas espaciais de *(x, y)* global, utiliza o mesmo limiar *T* na imagem inteira e múltipla, quando vários limiares são usados para segmentar a imagem em mais de uma categoria (GONZALEZ, 2010). Neste trabalho, foi utilizada a limiarização global, com o mesmo limiar da binarização *T* aplicado de maneira uniforme em toda a imagem.

Figura 18: Limiarização por intensidade, (a) imagem original em níveis de cinza e (b) imagem binarizada.

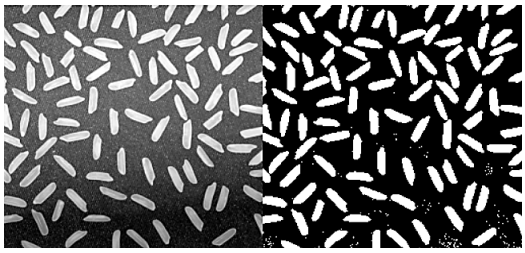

(a) (b)

Fonte: *Mathworks 2024.*

3.2.6 MÁSCARA GAUSSIANA 2D

A máscara gaussiana foi criada em homenagem a Carl Friedrich Gauss, em 1809 (STOER, 2002). Pode ser utilizada para suavização de dados, permitindo atenuar ruídos enquanto preserva as estruturas globais da imagem. A máscara pode ser calculada com base na função gaussiana 2D, definida pela Equação (2).

$$G(x,y) = \frac{1}{2\pi^2} exp(-\frac{(x-\mu_x)^2+(y-\mu_y)^2}{2\sigma^2}) \quad (2)$$

Na equação, x e y são as coordenadas dos pixels da imagem, enquanto μ_xe μ_y representam o centro da máscara gaussiana. O parâmetro σ define o desvio padrão, que controla o alcance da suavização. Dessa forma, quanto maior for σ, mais suave e extensa será a transição da máscara (RUSS, 2018).

Para este trabalho, foi utilizada a versão simplificada da fórmula gaussiana, excluindo o fator de normalização, representada pela Equação (3).

$$mask(x,y) = exp(-\frac{\boldsymbol{(x-\mu_x)^2+(y-\mu_y)^2}}{\boldsymbol{2\sigma^2}}) \quad (3)$$

A versão simplificada da máscara gaussiana traz eficiência na modulação da intensidade da imagem, realçando a área central e suavizando gradualmente as bordas. Apesar da expressão simplificada não contemplar o fator de normalização, que garantiria que a soma dos valores da máscara fosse igual a 1, o código compensa essa falta através de uma normalização manual. Depois de calcular a máscara, seus valores são ajustados para que fiquem no intervalo de 0 e 1, garantindo a aplicação adequada na imagem sem modificar significativamente a intensidade total (RUSS, 2018).

3.2.7 DISTÂNCIA EUCLIDIANA

No século III A.C., um matemático grego chamado Euclides de Alexandria, forneceu a base para a medida entre pontos e retas e René Descartes no século XVII, formalizou a equação como Distância Euclidiana. Calculando a distância entre dois pontos no espaço, aplicando a raiz quadrada da soma da diferença entre as coordenadas dos dois pontos, cada uma elevada ao quadrado (BOYER, 2019), como pode ser observado na Equação (4) abaixo:

$$d(P,Q) = \sqrt{(x2 - x1)^2 - (y2 - y1)^2} \quad (4)$$

Onde P(x_1,y_1) e Q(x_2,y_2) representam os vetores das coordenadas dos dois pontos, em um plano bidimensional. Para imagens, os pontos representam a posição de um pixel. Dessa forma, a distância euclidiana pode ser utilizada para criação de máscaras circulares e para segmentação de áreas de interesse em uma imagem, com base na distância do raio selecionado. Além disso, também pode ser usada com o objetivo de isolar ou agrupar uma área em uma imagem (GONZALEZ, 2010).

3.2.8 SEGMENTAÇÃO: MÉTODO *K - MEANS*

A clusterização consiste em uma técnica de aprendizado não supervisionado que organiza as informações em grupos homogêneos, segmentando a imagem em regiões de *k* grupos, denominados de *clusters.* Essa técnica procura identificar padrões, estruturas e relações implícitas nos dados, sem a necessidade de criar rótulos ou categorias. Os elementos de dentro de um *cluster* compartilham características semelhantes, enquanto os elementos de fora dos *cluster* apresentam diferenças significativas (RIBEIRO *et al*., 2022).

O algoritmo *K-Means* representa um dos métodos mais utilizados na clusterização e desempenha papel importante na segmentação de imagens, dividindo a imagem em regiões, baseadas em características como cor, intensidade, forma, textura e tamanho, organizando os dados em *k* clusters de acordo com a proximidade. Além disso, apresenta implementação simples e rapidez em dados com tamanho pequeno e médio e flexibilidade (MATTE *et al*., 2019).

O processo começa com a escolha de *k*. Em seguida, o algoritmo seleciona aleatoriamente *k* pontos, que servirão como centróides iniciais, representando o centro de cada *cluster.* Com os centróides definidos, temos a etapa de atribuição dos pontos aos *clusters*, onde cada ponto será associado ao *cluster* com centróide mais próximo, normalmente utiliza a distância euclidiana para determinar a proximidade. Depois da atribuição, ocorre a etapa de atualização dos centróides, onde precisam ser recalculados. O novo centróide de cada *cluster* equivale à média de todos os pontos atribuídos a aquele grupo. Por fim, o algoritmo repete o processo de atribuição até os centróides se estabilizarem, ou seja, o critério de parada seja atingido (Figura 19) (RIBEIRO *et al*., 2022).

Figura 19: Exemplo da aplicação do algoritmo de agrupamento *K-means*, (a) k = 2, (b) k = 3, (c) k = 10 e (d) imagem original.

(a) (b) (c) (d)

Fonte: Adaptado de (BISHOP, 2006).

4. MATERIAIS E MÉTODOS

4.1 MATERIAIS

4.1.1 BANCO DE DADOS

As imagens utilizadas neste trabalho foram obtidas a partir do banco de dados *Structured Analysis of the Retina* (STARE) (HOOVER, 2024), disponível publicamente e com distribuição aberta, podendo ser acessado de forma *online,* através do *site* oficial. Essa base de dados pode ser utilizada no desenvolvimento de algoritmos para identificação de diversas doenças oculares, pois, disponibiliza uma vasta gama de imagens associadas a patologias, como retinopatia diabética, degeneração macular relacionada à idade forma seca e forma úmida, Neovascularização coroidal, Oclusão da veia central da retina e Fibras nervosas mielinizadas (VERAS, 2014; HOOVER *et al*., 2024).

O banco de dados STARE, faz parte de um projeto iniciado em 1975 na Universidade da Califórnia, por Michael Goldbaum. As imagens do banco foram capturadas utilizando a câmera *TopCon* TRV-50 com uma angulação de 35° de *Field of View* (FOV). O conjunto de dados possui 402 imagens de retinografia, com tamanho de 700 × 605 *pixels* de largura e altura*,* no formato *.ppm (Portable Pixmap Format)* e com oito *bits* por canal de cor, das quais 36 delas apresentam drusas (VERAS, 2014; HOOVER *et al*., 2024).

O principal desafio identificado nos dados do banco de dados foi à ausência de informações completas e detalhadas sobre as drusas. O banco de dados STARE, disponibiliza o *Ground Truth* mais detalhado somente para estruturas, como os vasos sanguíneos e o disco óptico, que possuem rótulos e máscaras etiquetadas. Os demais dados estão, em formato de anotações, identificando as doenças em cada imagem, segundo os especialistas. Entretanto, essas anotações não contêm rótulos importantes ou máscaras, marcando e enfatizando a localização, a quantidade ou o tamanho das drusas, justificando o diagnóstico apresentado. Essas informações são fundamentais para realizar uma comparação direta entre os resultados da segmentação automática e os padrões definidos pelos especialistas, para verificar se os *pixels* identificados pelo algoritmo correspondem precisamente às drusas presentes na imagem.

4.1.2 MATLAB

O *Matrix Laboratory* (MATLAB), foi desenvolvido na década de 70 por Cleve Moler, com o objetivo de ser uma ferramenta projetada para aplicações matemáticas e científicas, ganhando popularidade devido a sua flexibilidade e facilidade de uso. Com o passar dos anos, a ferramenta foi aprimorada suportando uma ampla diversidade de áreas como acadêmicas e industriais, incluindo o processamento de imagens. A *Toolbox* de Processamento de imagens introduzida anos depois, foi inovadora no campo de análise e manipulação de imagens digitais. Permitindo diversas aplicações como filtragem, segmentação, compressão (MOLER, 2018).

Para esse trabalho foi utilizado a versão R2024b o *software* foi escolhido devido suas características e aplicações tais como a sua capacidade de analisar imagens digitais, e efetuar modificações facilitando o pré-processamento e a segmentação necessária para o trabalho além de poder visualizar dados permitindo a inspeção detalhada das imagens de retinografia, identificando características das drusas e análise dos resultados gerados pelo algoritmo.

4.2 MÉTODOS

A Figura 20 apresenta o diagrama de blocos da estratégia adotada para o desenvolvimento do algoritmo, estruturada em três etapas: pré-processamento, processamento e pós-processamento. Na etapa de pré-processamento, foram realizados procedimentos para aprimorar a qualidade da imagem. O processamento consistiu na segmentação das características, enquanto o pós-processamento refinou o resultado da segmentação, gerando a imagem final com as drusas extraídas.

Figura 20: Diagrama de Blocos da Estratégia de Segmentação.

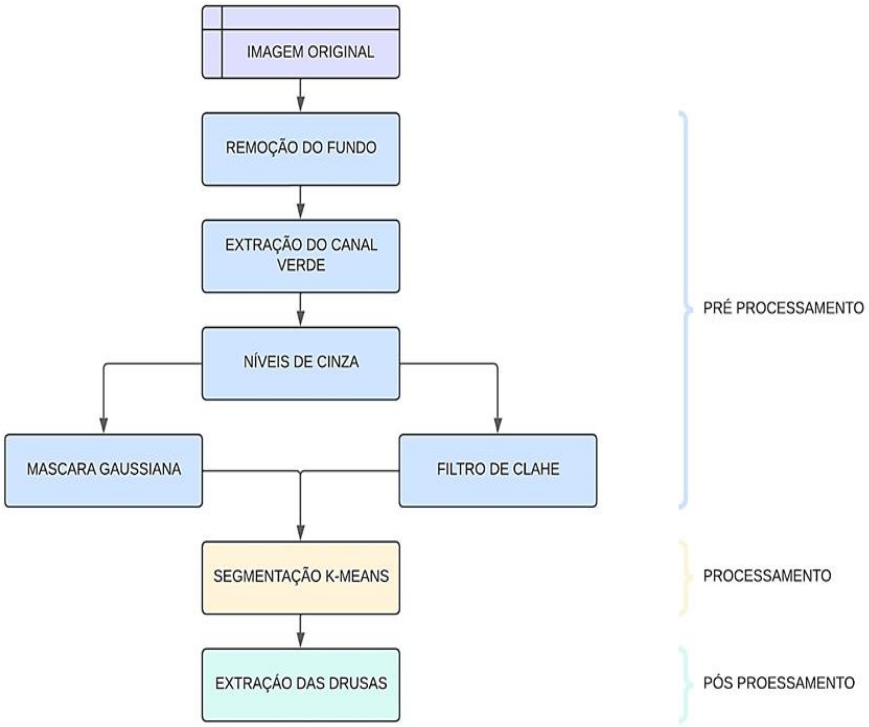

Fonte: Autoria própria.

4.3 PRÉ-PROCESSAMENTO

A etapa de pré-processamento começou com a avaliação e leitura de cada imagem no formato *.ppm*, presente no banco de dados. Durante essa análise, foi identificada a existência de uma região periférica com coloração esverdeada que não deveria fazer parte da imagem, dificultando o processo de segmentação das drusas.

A coloração esverdeada do *background* nas imagens de retinografia, interferiu no processo de segmentação das drusas devido a diversos fatores. O primeiro foi a semelhança de intensidade dos *pixels* entre o fundo e as drusas, tornando difícil a diferenciação dessas regiões. Além disso, o fundo da imagem funcionou como um ruído visual, trazendo informações irrelevantes que poderiam atrapalhar no processamento. Outro ponto importante foi o contraste reduzido entre as drusas e o fundo, dificultando a identificação clara das estruturas de interesse. Por fim, a variação na iluminação também tornou o fundo ainda mais heterogêneo, causando mais interferências.

Em razão disso, foi realizado a remoção dessa área, por não fazer parte da região de interesse, com o objetivo de eliminar o *background* esverdeado para melhorar o contraste e facilitar o processo de segmentação e identificação do objeto na imagem.

Para remoção do *backgorund*, foi realizado a conversão da imagem original para tons de cinza, que inicialmente estava no modelo de cores RGB. Com a imagem em escala de cinza criamos uma máscara binária, utilizando como base a técnica de limiarização global, onde o limiar fixo de intensidade determinado foi de 41, com o objetivo de separar o objeto do fundo, como ilustrado na Figura 21.

Figura 21: Binarização, (a) imagem original, (b) imagem binarizada.

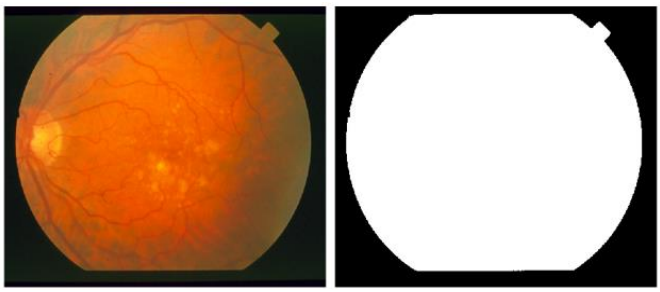

(a) (b)

Fonte: Autoria própria.

Em um caso específico, a imagem de retinografia apresentou sombras e regiões mais escuras na parte interna, o que acabou interferindo diretamente na segmentação e identificação das drusas que estavam presentes naquela região. As drusas localizadas nas outras regiões foram segmentadas sem interferência, como mostrado na Figura 22.

Figura 22: Binarização, (a) imagem original com sombra e regiões escuras e (b) imagem binarizada.

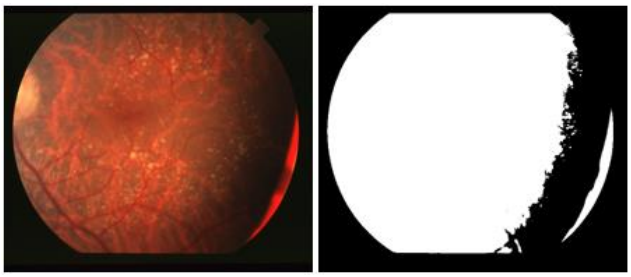

(a) (b)

Fonte: Autoria própria.

Após a limiarização, a máscara binária foi refinada com técnicas morfológicas, para tratar informações resultantes do processo de segmentação. Primeiro, as áreas desconectadas dentro do objeto foram preenchidas e em seguida, foi aplicado a operação morfológica abertura, utilizando um elemento estruturante circular de raio 50 (Figura 23(a)). Essa etapa teve como objetivo de remover pequenas imperfeições e suavizar os contornos, resultando em uma máscara mais limpa e precisa. Para finalizar, foi usada a máscara sobre a imagem original, criando um fundo preto e destacando a área de interesse (Figura 23(b)).

Figura 23: Remoção do *background*, (a) imagem binarizada com operação de abertura e (b) imagem com *background* removido.

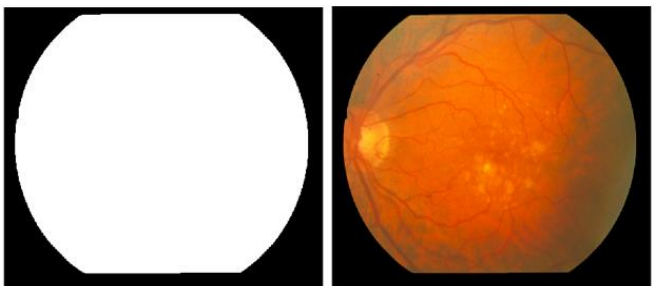

(a) (b)

Fonte: Autoria própria

Após a remoção do *background,* os três canais da imagem original (Figura 24 (a)), foram extraídos e analisados separadamente para que fosse possível selecionar o canal com melhor visualização da região de interesse. Ao analisar os três canais da imagem, foi verificado que o canal verde (Figura 24(c)), ofereceu melhor iluminação e contraste para identificação dos detalhes anatômicos da retina, como por exemplo vasos sanguineos, mácula, drusas, disco óptico, entre outras.

Além disso, o canal verde também apresentou menos interferência de ruídos quando comparado aos canais vermelho e azul. Isso ocorre porque as imagens do canal vermelho (Figura 24(b)), tendem a apresentar maiores intensidades, sendo mais brilhantes e saturadas, enquanto as imagens do canal azul (Figura 24(d)), normalmente evidenciam mais ruído, dificultando a visualização de estruturas da retina.

Figura 24: Extração dos canais de cor, (a) imagem original, (b) canal vermelho da imagem, (c) canal verde da imagem e (d) canal azul da imagem.

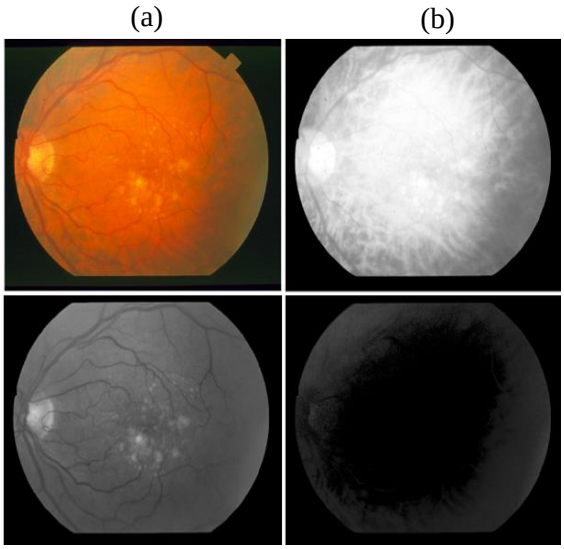

Fonte: Autoria própria.

Ao final da extração do canal verde, foi observado que, embora essa etapa tenha proporcionado melhor iluminação e contraste em relação aos demais canais de cor, ainda seria necessário realizar um aprimoramento na visibilidade da região de interesse. Pois, a extração do canal verde, por si só, não foi suficiente para enfatizar adequadamente as drusas, estruturas essas que são essenciais para o desenvolvimento deste trabalho.

Dessa forma, foram aplicadas técnicas complementares de processamento digital de imagem, como realce de contraste, filtragem e equalização de histograma, a fim de destacar os detalhes mais sutis e compensar as variações de iluminação. Essa abordagem possibilitou uma segmentação e visualização mais precisa das drusas.

Inicialmente, a imagem resultante da extração do canal verde foi convertida para níveis de cinza (Figura 25(a)), e, em seguida, uma máscara gaussiana foi criada para enfatizar a região central da imagem. Conforme descrito na literatura e explicado no capítulo dois, drusas localizadas na periferia da retina, fora da região macular, geralmente não comprometem significativamente a função visual e não estão diretamente associadas ao desenvolvimento da DMRI. No entanto, quando as drusas se encontram na região macular, elas podem indicar um marcador de risco para a DMRI, com possibilidade de progressão para estágios mais graves da doença. A máscara ajustou o contraste e iluminou apenas as regiões centrais da imagem, preservando as características originais das bordas.

Por fim, aplicamos CLAHE de forma global, aumentando o contraste em toda a imagem, garantindo assim que detalhes sutis sejam destacados (Figura 25(b)).

Figura 25: Realce da região central da imagem, (a) imagem em níveis de cinza, (b) imagem após aplicação da Máscara Gaussiana e filtro de CLAHE.

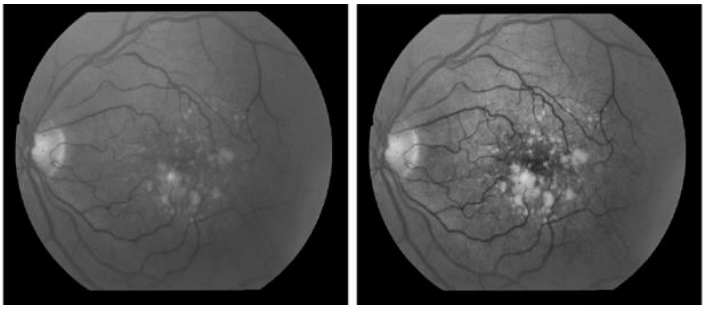

(a) (b)

Fonte: Autoria própria

4.4 PROCESSAMENTO

A segmentação foi considerada, como parte fundamental do algoritmo desenvolvido, pois, a partir dela foi possível delimitar e extrair as regiões de interesse da imagem pré-processada. A técnica de segmentação adotada neste trabalho foi o algoritmo de *K-means,* com o objetivo de organizar os *pixels* da imagem em grupos, de acordo com características semelhantes.

Na etapa de segmentação os índices dos *clusters* foram reorganizados em uma matriz bidimensional, representando visualmente cada região segmentada. O algoritmo dividiu os níveis de cinza da imagem em sete *clusters* distintos, correspondendo a diferentes intensidades de *pixels*, com o objetivo de separar estruturas como, disco óptico, vasos sanguíneos, *background* (fundo), drusas, entre outras. Após essa etapa, o algoritmo seleciona aleatoriamente *k,* como centróides iniciais, representando o centro de cada *cluster.* Com os centróides definidos, cada *pixel* será atribuído ao *cluster* com centróide mais próximo. Por fim, calcula os centróides e repete o processo de atribuição até que o critério de parada seja atingido.

Em seguida, a análise realçou as características das drusas, identificadas como pertencentes ao *cluster* com a maior intensidade média de *pixels*, indicando que essas regiões possuíam valores de intensidade superiores em comparação com outras estruturas presentes na imagem. Isso ocorre, porque, as drusas são depósitos lipídicos, que

apresentaram uma maior refletância. O *cluster* foi selecionado com base nos valores máximos dos centros calculados pelo *k-means*.

Para garantir que apenas as áreas mais relevantes fossem mantidas, foi aplicado um filtro de área que seleciona as 100 maiores regiões conectadas, eliminando pequenos ruídos e objetos irrelevantes presentes na imagem. Por fim, buracos internos nas drusas foram preenchidos para gerar regiões contínuas e bem definidas, como mostrado na Figura 26.

Figura 26: Segmentação das drusas, (a) imagem após aplicação da Máscara Gaussiana e filtro de CLAHE e (b) imagem resultante após segmentação *K-means*.

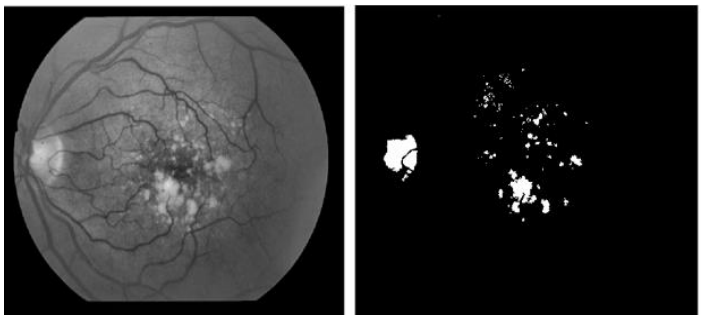

(a) (b)

Fonte: Autoria própria.

4.5 PÓS-PROCESSAMENTO

Após o processo de segmentação, foi constatado que as imagens apresentavam estruturas indesejadas, que não faziam parte da região de interesse, como por exemplo, o disco óptico e áreas com iluminações disformes, sendo necessário corrigi-las. Com o objetivo de minimizar essas inconsistências, foi realizada a etapa de pós-processamento.

De forma conjunta, foi realizado um aprimoramento nos resultados encontrados, removendo as drusas localizadas fora da região macular, de modo a enfatizar aquelas presentes na área central da retina, pois, representam maior risco para o desenvolvimento da DMRI.

Ao concluir a análise das imagens provenientes da etapa de segmentação, foi definida uma estratégia (Figura 27) baseada na localização das características que seriam removidas.

Figura 27: Diagrama de Blocos da Estratégia de Segmentação Aprimorada

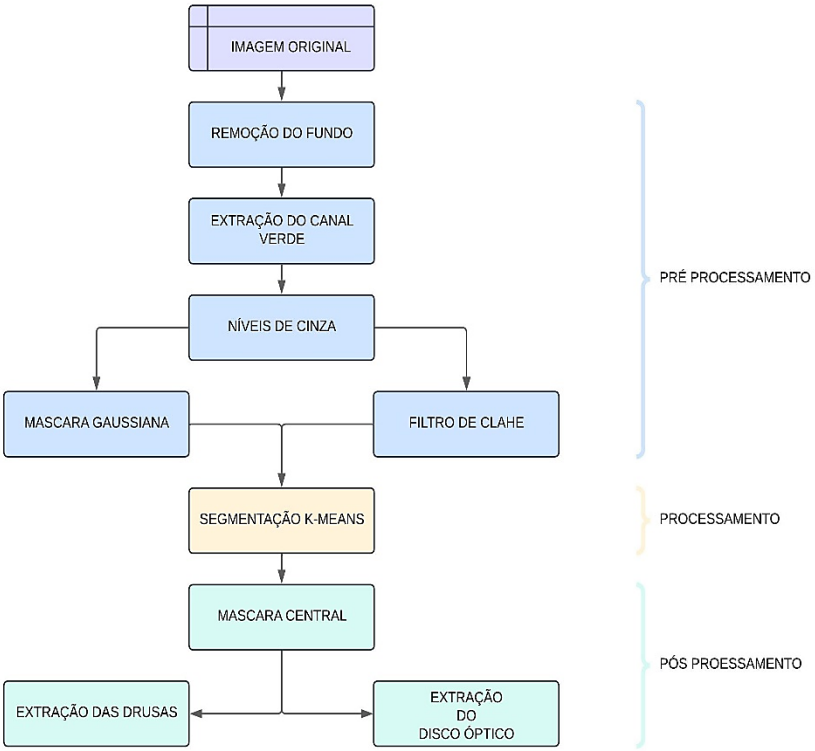

Fonte: Autoria própria.

A correção das estruturas indesejadas e o aprimoramento dos resultados obtidos foram baseados na localização da região central da imagem, pois, como explicado anteriormente, quando as drusas estão na região periférica da retina, não costumam estar associadas diretamente ao desenvolvimento da DMRI. Mas, quando estão localizadas na região macular, os indivíduos têm grande risco de apresentar DMRI, podendo avançar para a forma exsudativa ou até mesmo atrofia geométrica.

Para isolar a região central e extrair somente as estruturas presentes nela, foi criado uma máscara circular, calculando a distância euclidiana de cada ponto da imagem em relação ao seu centro, utilizando a fórmula da distância entre dois pontos no plano 2D e o tamanho da área macular. Então, todos os pontos com distância até o centro menor ou igual ao raio definido, recebem valor 1 e ficam dentro da máscara. Dessa forma, foram removidas as drusas localizadas fora da área central, o disco óptico (DO), quando posicionado lateralmente e a alta iluminação nas extremidades da retina, como ilustrado na Figura 28.

Figura 28: Segmentação da região central, (a) imagem resultante após segmentação *K-means* e (b) imagem resultante da segmentação após aplicação da Máscara Circular.

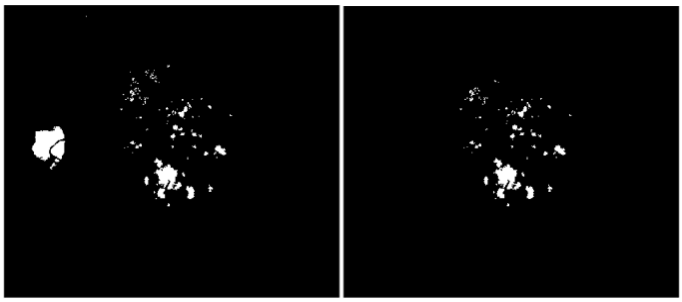

(a) (b)

Fonte: Autoria própria.

5. RESULTADOS E DISCUSSÕES

Neste capítulo, serão mostrados os resultados e as discussões geradas pela aplicação das técnicas básicas para a segmentação das drusas. Os resultados apresentados, juntamente com as métricas e classificações de avaliação, refletem a eficácia e o desempenho da estratégia adotada. Além disso, também serão abordadas comparações entre a segmentação desenvolvida e máscaras modelos criadas manualmente.

O método proposto foi aplicado somente às imagens identificadas com a presença de drusas no banco de dados selecionado. Inicialmente foram testadas 34 imagens das 36 selecionadas, pois 2 imagens foram removidas da análise, devido à má qualidade ocasionada por alta luminosidade em regiões centrais, periféricas e no disco óptico.

5.1 RESULTADOS

5.1.1 MÉTRICAS E CLASSIFICAÇÕES DE AVALIAÇÃO

Foi adotado um método padronizado para a avaliação das imagens, estabelecendo critérios específicos a fim de classificar os *pixels*. Quatro classificações foram consideradas para essa análise: verdadeiro positivo (TP), verdadeiro negativo (TN), falso positivo (FP) e falso negativo (FN). O verdadeiro positivo (VP) ocorre quando o algoritmo identifica corretamente um *pixel* como drusa, a classificação verdadeiro negativo (VN) acontece quando os *pixels* não pertencentes à drusa são adequadamente reconhecidos como não sendo drusas. Em casos de erro de identificação, temos o falso positivo (FP), quando os *pixels* são incorretamente classificados como drusas, e o falso negativo (FN), quando os *pixels* são classificados erroneamente como tecido normal, sendo na verdade drusas.

Para fins de avaliação do desempenho e da eficácia do algoritmo de segmentação das drusas, foram aplicadas três métricas principais na etapa de comparação entre a segmentação proposta e a máscara modelo criada de forma manual, a acurácia, a sensibilidade e a especificidade. A acurácia mede o percentual total de classificações corretas, englobando tanto a detecção de drusas quanto a identificação de tecidos normais no conjunto de *pixels* analisados, calculada através da Equação (5). Por sua vez, a sensibilidade demonstra a eficiência na detecção de drusas, avaliando a proporção de verdadeiros positivos e a capacidade do sistema de reconhecer as lesões presentes, pode ser calculada através da Equação (6). Por fim, a especificidade mensura a precisão na

identificação dos *pixels* não pertencentes às drusas, onde a Equação (7) determina a taxa de sucesso na classificação correta dos tecidos normais, evitando identificações falsas de drusas nas áreas saudáveis.

$$\text{Acurácia} = \frac{(VP + VN)}{(VP + VN + FP + FN)} \tag{5}$$

$$\textit{Sensibilidade} = \frac{VP}{(VP + FN)} \tag{6}$$

$$\textit{Especificidade} = \frac{VN}{(VN + FP)} \tag{7}$$

5.1.2 COMPARAÇÃO ENTRE A SEGMENTAÇÃO PROPOSTA E A MÁSCARA MODELO CRIADA

Os cálculos das métricas de avaliação foram realizados a partir da comparação entre a máscara modelo e a segmentação proposta, em conjunto com as quatro possíveis classificações dos *pixels*.

Diante da ausência de informações completas e detalhadas sobre as drusas no banco de dados, como foi explicado na seção quatro, foi necessário a elaboração de máscaras rotuladas manualmente, com o propósito de identificar, demarcar e enfatizar, a localização, o tamanho e o formato das drusas. Tarefa está realizada neste trabalho, permitindo a comparação com as imagens geradas pelo algoritmo desenvolvido e a validação do desempenho dos resultados obtidos.

Para a realização das comparações, foram estabelecidas duas categorias para as máscaras criadas, a primeira foi categorizada como, máscaras manuais com todas as drusas da imagem marcadas e chamada de “máscara modelo geral”. A segunda categoria foi determinada como, máscaras manuais com drusas identificadas somente na região central da imagem e chamada de “máscara modelo central”. Esse processo consistiu em analisar cada imagem individualmente e pintar manualmente, com precisão as regiões onde as drusas estavam presentes. Com esse propósito foram aplicadas funções

algorítmicas que permitiram a criação da máscara de segmentação utilizando contornos ativos a partir das imagens originais.

Esse método apresenta caráter qualitativo e subjetivo, pois depende do julgamento visual e possui menor robustez quando comparada a um *Ground Truth,* elaborado por especialistas da área. As máscaras, criadas neste trabalho, foram limitadas nas características das drusas, como a forma, textura e a cor observadas na imagem, onde desempenharam um papel fundamental na comparação dos resultados. Serviram como referência para avaliar o algoritmo, permitindo identificar visualmente se as regiões detectadas como drusas pela estratégia desenvolvida coincidiam com as áreas suspeitas.

Para a etapa de comparações, foram estabelecidos dois cenários: no primeiro cenário foi realizada a comparação entre as máscaras modelo geral (Figura 29(b)) e as imagens resultantes da etapa de segmentação do algoritmo (Figura 29(a)). No segundo cenário foi comparado as máscaras modelo central com as imagens resultantes do pós-processamento da estratégia (Figura 29(d)), após a aplicação da máscara circular (Figura 29(c)), tendo ênfase nas lesões localizadas na região central.

Figura 29: Comparação nos cenários criados: (a) imagem resultante da segmentação e (b) máscara modelo geral, (c) imagem resultante do pós-processamento e (d) máscara modelo central.

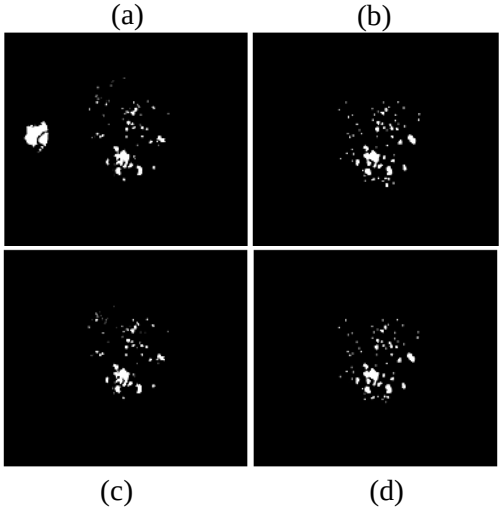

Fonte: Autoria própria.

Após realização dos testes, foi observado que no primeiro cenário o algoritmo apresentou os valores médios de 95,26% de acurácia, 30,59% de sensibilidade e 98,62% de especificidade. No segundo cenário verificamos que os valores médios de acurácia,

sensibilidade e especificidade aumentaram, quando comparado ao primeiro, mostrando 97,53% de acurácia, 40,58% de sensibilidade e 99,18% de especificidade, como ilustrado nas (Tabela 1) e (Tabela 2).

Tabela 1: Desempenho do algoritmo de segmentação das drusas sem máscara circular.

Imagem	VP	VN	FP	FN	ACC	SEN	ESP
1	8017	389180	8268	18035	93,79%	30,77%	97,92%
2	17514	382590	3131	20265	94,48%	46,36%	99,19%
3	3659	384542	33194	2105	91,66%	63,48%	92,05%
4	1393	409788	3707	8612	97,09%	13,92%	99,10%
5	1086	404126	8099	10189	95,68%	9,63%	98,04%
6	3961	399750	4248	15541	95,33%	20,31%	98,95%
7	97	420028	1914	1461	99,20%	6,23%	99,55%
8	8520	377441	33968	3571	91,14%	70,47%	91,74%
9	2667	403143	6190	11500	95,82%	18,83%	98,49%
10	1925	403641	13530	4404	95,77%	30,42%	96,76%
11	8583	400234	805	13878	96,53%	38,21%	99,80%
12	12017	394197	5048	12238	95,92%	49,54%	98,74%
13	759	410581	7797	4363	97,13%	14,82%	98,14%
14	17614	376701	3072	26113	93,11%	40,28%	99,19%
15	7735	400617	3519	11629	96,42%	39,95%	99,13%
16	5316	391520	11033	15631	93,70%	25,38%	97,26%
17	5528	398378	3220	16374	95,37%	25,24%	99,20%
18	4304	398862	4705	15629	95,20%	21,59%	98,83%
19	8725	388670	536	25569	93,84%	25,44%	99,86%
20	2266	406787	5293	9154	96,59%	19,84%	98,72%
21	3205	410281	3510	6504	97,64%	33,01%	99,15%
22	2850	398650	17686	4314	94,81%	39,78%	95,75%
23	1266	402323	14715	5196	95,30%	19,59%	96,47%
24	9531	392350	5906	15713	94,90%	37,76%	98,52%
25	9568	392340	3264	18328	94,90%	34,30%	99,17%
26	1929	374630	29773	17168	88,92%	10,10%	92,64%
27	10788	399958	7368	5386	96,99%	66,70%	98,19%
28	8878	389037	14369	11216	93,96%	44,18%	96,44%
29	3725	382646	29461	7668	91,23%	32,70%	92,85%
30	3404	381216	29936	8944	90,82%	27,57%	92,72%
31	6437	387503	1391	28169	93,02%	18,60%	99,64%
32	11598	391696	4298	15908	95,23%	42,17%	98,91%

33	2434	407781	4613	8672	96,86%	21,92%	98,88%
34	7868	397871	8368	9393	95,81%	45,58%	97,94%

Fonte: Autoria própria.

Tabela 2: Desempenho do algoritmo de segmentação das drusas com máscara circular.

Imagem	VP	VN	FP	FN	ACC	SEN	ESP
1	3087	412982	6273	1158	98,25%	72,72%	98,50%
2	16458	387610	2698	16734	95,41%	49,58%	99,31%
3	2053	406428	14364	655	96,45%	75,81%	96,59%
4	1329	415226	157	6788	98,36%	16,37%	99,96%
5	1018	411290	3293	7899	97,36%	11,42%	99,21%
6	3407	414472	641	4980	98,67%	40,62%	99,85%
7	88	422308	0	1104	99,74%	7,38%	100,00%
8	6500	398972	15741	2287	95,74%	73,97%	96,20%
9	1892	413852	2118	5638	98,17%	25,13%	99,49%
10	1041	419200	283	2976	99,23%	25,91%	99,93%
11	7903	405755	724	9118	97,68%	46,43%	99,82%
12	10544	403617	4278	5061	97,79%	67,57%	98,95%
13	480	420177	1029	1814	99,33%	20,92%	99,76%
14	12934	397302	2285	10979	96,87%	54,09%	99,43%
15	7625	404391	1494	9990	97,29%	43,29%	99,63%
16	4917	405215	918	12450	96,84%	28,31%	99,77%
17	5455	405279	435	12331	96,99%	30,67%	99,89%
18	1591	410308	1288	10313	97,26%	13,37%	99,69%
19	7479	405861	198	9962	97,60%	42,88%	99,95%
20	2237	413205	386	7672	98,10%	22,58%	99,91%
21	3205	413718	245	6332	98,45%	33,61%	99,94%
22	1776	406931	13824	969	96,51%	64,70%	96,71%
23	1109	407033	14233	1125	96,37%	49,64%	96,62%
24	5875	410802	1478	5345	98,39%	52,36%	99,64%
25	8841	405772	764	8123	97,90%	52,12%	99,81%
26	1577	409714	53	12156	97,12%	11,48%	99,99%
27	10687	401918	6555	4340	97,43%	71,12%	98,40%
28	8350	404366	3500	7284	97,45%	53,41%	99,14%
29	3719	409645	2985	7151	97,61%	34,21%	99,28%
30	3388	405767	5949	8396	96,61%	28,75%	98,56%
31	6259	399462	116	17663	95,80%	26,16%	99,97%
32	10309	400867	3197	9127	97,09%	53,04%	99,21%

33	2383	413570	391	7156	98,22%	24,98%	99,91%
34	6158	409039	3318	4985	98,04%	55,26%	99,20%

Fonte: Autoria própria

5.1.3 COMPARAÇÃO ENTRE A SEGMENTAÇÃO PROPOSTA E ALGORTIMOS DA LITERATURA

Foi realizada uma comparação entre a estratégia desenvolvida e outros estudos presentes na literatura, conforme apresentado na Tabela 3. Embora a estratégia utilizada nesses trabalhos fossem distintas do método proposto, os objetivos eram semelhantes, com foco na segmentação de drusas em imagens do fundo de olho. Essa segmentação teve como principal finalidade a identificação e visualização das drusas, visando auxiliar médicos e especialistas no diagnóstico e monitoramento da DMRI, com o intuito de aumentar a precisão na detecção precoce da doença.

Tabela 3: Comparação entre os métodos da literatura e o do algoritmo proposto.

Método	Banco de dados	ACC	SEN	ESP
Waseem *et al*. (2014)	STARE	96,00%	96,00%	97,00%
Mittal e Kumari (2015)	STARE e ARIA	96.17%	89.81%	99.00%
Kim e Kim (2018)	Seoul National University Bundang Hospital	-	93,37%	-
Khalid *et al*. (2020)	STARE e AFIO	92.34%	93.3%	92,00%
Monteiro e Sarmento (2020)	STARE	96.79%	96.15%	99.70%
Yellapragada *et al*. (2021)	National Eye Institute's Online Database of Genotypes and Phenotypes	94,00%	-	-
Fang *et al*. (2022)	-	97,14%	-	-
Método proposto sem ênfase na região central	STARE	95,26%	30,59%	98,62%
Método proposto com ênfase na região central	STARE	97,53%	40,58%	99,18%

Fonte: Autoria própria

Em termos gerais, os resultados de acurácia e especificidade do método proposto foram comparáveis ou superiores aos apresentados na literatura. No entanto, a sensibilidade não demonstrou desempenho no mesmo patamar dos demais, ficando inferior no intervalo em comparação aos outros estudos.

5.2 DISCUSSÕES

Os resultados obtidos demonstram que foi possível segmentar as drusas, duras e moles, nas imagens de retinografia com 97,53% de acurácia e 99,18% de especificidade. No entanto, os valores de sensibilidade alcançados não apresentaram desempenho relevante, principalmente devido á interferência negativa de artefatos na identificação precisa das drusas.

Durante a fase de processamento, foi constatado que o algoritmo gerou como resultado a segmentação desses artefatos que não pertenciam à região de interesse. Além das drusas, a segmentação também incluiu o disco óptico (DO) e regiões, tanto centrais quanto periféricas, com alta luminosidade.

O disco óptico, por ser uma estrutura naturalmente mais clara e bem definida na imagem, compartilha características semelhantes às das drusas, especialmente em termos de intensidade e contraste. Da mesma forma, as áreas de alta luminosidade, como reflexos ou artefatos, apresentam *pixels* com intensidades elevadas que se assemelham aos das lesões. Como resultado, o algoritmo acaba identificando essas estruturas e regiões como parte das drusas, agrupando-as no mesmo *cluster*, o que prejudica a precisão da segmentação e compromete a correta extração das lesões.

Esse comportamento foi amplificado pelo fato de que a técnica de segmentação utilizada foi o algoritmo de *k-means*, que agrupa os *pixels* da imagem com base em atributos como intensidade, cor e textura. O algoritmo de *k-means* não leva em consideração o contexto anatômico ou a funcionalidade de cada região.

Visando a remoção desses artefatos e o aprimoramento dos resultados obtidos, foi aplicado a etapa de pós-processamento nas imagens. Dessa forma, foi utilizado uma máscara circular, removendo o DO das imagens, quando posicionado lateralmente (Figura 30(a)), eliminando as regiões periféricas com alta luminosidade nas imagens (Figura 30(b)) e extraindo as drusas localizadas fora da região macular (Figura 30(c)), de modo a enfatizar aquelas presentes na área central da retina, pois representam maior risco para o desenvolvimento da DMRI.

Figura 30 : Resultado da segmentação e aplicação da máscara circular, (a) imagem com dico optico segmentado e extraido (b) imagem com região central com alta luminosidade segmentada e extraída e (c) imagem com drusas segmentadas e extração da região central.

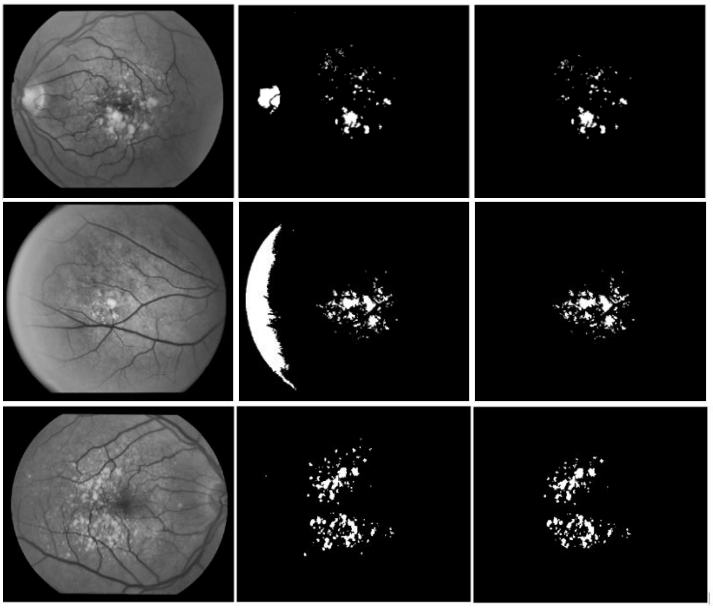

Fonte: Autoria própria

Após a aplicação da máscara circular na etapa de pós-processamento, foi observado um resultado significativo na extração das estruturas pertencentes à região de interesse. A máscara foi eficaz em isolar artefatos que interferiam na precisão da identificação das drusas. Esse aperfeiçoamento pode ser verificado, principalmente, na variação dos valores de acurácia, especificidade e sensibilidade, quando foi realizada a comparação entre as máscaras modelos criadas manualmente e a segmentação proposta. Esses valores presentaram um aumento substancial quando comparadas aos valores obtidos sem a aplicação da máscara circular no pós-processamento.

No entanto, apesar dos resultados promissores, a aplicação da máscara circular apresentou limitações em algumas imagens nas quais o disco óptico (DO) estava centralizado frontalmente e áreas de alta luminosidade incidiam na região central. Nesses casos, a remoção dessas áreas não foi realizada corretamente, pois, a máscara desenvolvida, tinha como objetivo remover somente regiões periféricas a sua aplicação, ou seja, remover estruturas presentes fora da mácula, ilustrado nas (Figura 31(a)) e (Figura 31(b)).

Ainda que, em certas circunstâncias, a máscara circular não tenha removido de maneira adequada o disco óptico (DO) e as áreas com alta iluminação central, o algoritmo conseguiu, segmentar as drusas presentes nas imagens, conforme demonstrado na Figura 31.

Figura 31: Resultado da segmentação e aplicação da máscara circular, (a) imagem com dico optico segmentado e (b) imagem com região central com alta luminosidade.

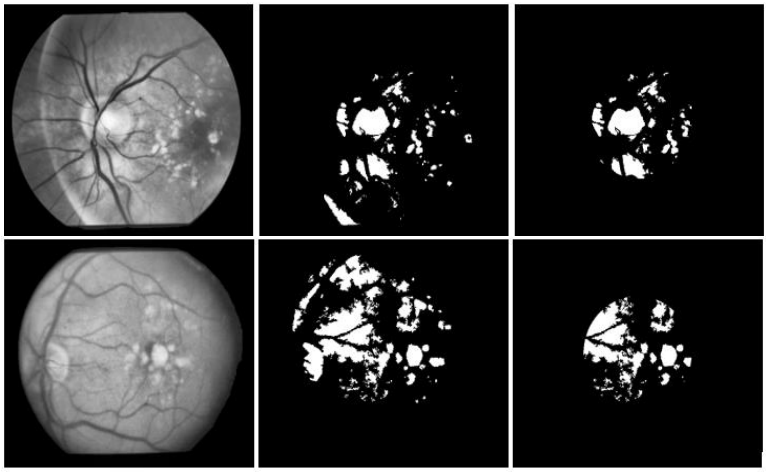

(a)

(b)

Fonte: Autoria própria

Em alguns casos, embora as drusas tenham sido segmentadas, a extração foi insuficiente (Figura 32). Isso ocorreu, principalmente porque os *pixels* do disco óptico (DO) apresentavam intensidades muito maiores, quando comparados as das drusas que não foram detectadas pelo algortimo, que mostravam valores de intensidade mais baixos. No algoritmo *k-means*, os centroides são formados com base nas intensidades dos *pixels*. Então a essa diferença de intensidade entre o DO e as drusas fez com que o algoritmo os separasse em *clusters* distintos.

Figura 32: (a) imagem realçada e (b) imagem com drusas insuficientes.

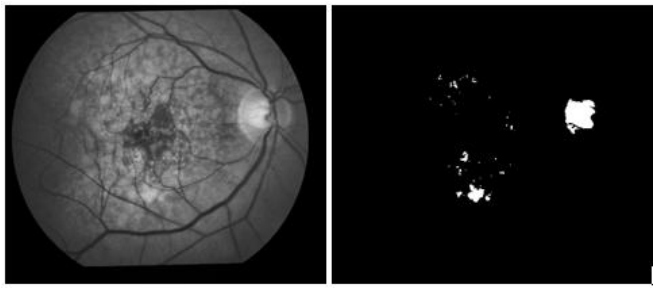

(a) (b)

Fonte: Autoria própria

A Figura 33(a) mostra a imagem resultante da segmentação *k-means*, sobreposta à imagem original, destacando as drusas e artefatos como o disco óptico. A Figura 33(b) apresenta a imagem após a aplicação da máscara circular, também sobreposta à imagem original, evidenciando as drusas na região central da retina, enquanto remove as drusas das áreas periféricas da imagem e o disco óptico. Nas figuras, as estruturas destacadas em azul representam as drusas e o disco óptico, identificados pelo algoritmo nas imagens de retinografia. Além disso, a Figura 33(c) e Figura 33(d) ilustram a imagem final sem a presença de artefatos, como o disco óptico e as regiões com alta luminosidade.

Figura 33: Resultado da aplicação do algoritmo, (a) imagem final com disco óptico e drusas identificados, (b) imagem final com DO e região central extraída, (c) imagem final sem artefato e (d) imagem final sem artefatos com região central extraída.

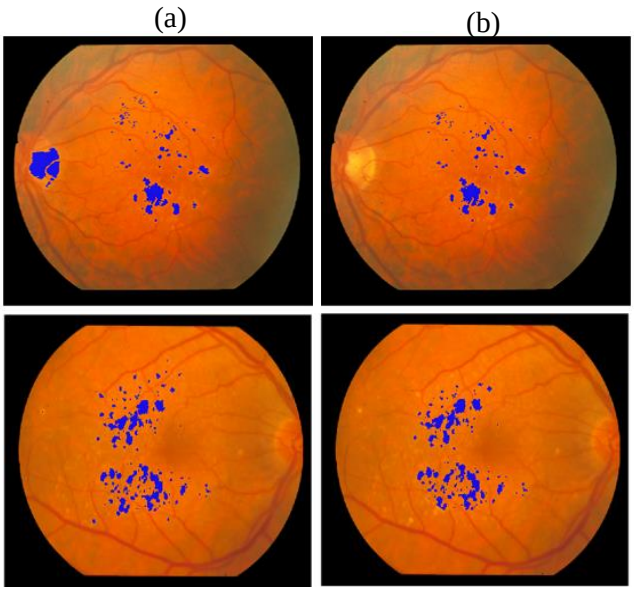

Fonte: Autoria própria.

6. CONCLUSÕES

A Degeneração Macular Relacionada a Idade (DMRI) representa uma das principais causas de perda progressiva da visão central e cegueira irreversível em idosos. Diante disso, identificar a doença nos estágios iniciais, passou a ser fundamental, para realização de tratamentos que possam retardar ou minimizar sua progressão.

Entretanto, o diagnóstico da DMRI apresenta diversos desafios que podem comprometer a precisão dos resultados, como por exemplo a quantidade limitada de profissionais qualificados para diagnosticar a doença a partir dos exames de imagem, a experiencia dos profissionais e principalmente a qualidade das imagens de retinografia, que pode ser afetada diretamente por interferências externas. Algumas dessas interferências são, posição do paciente em frente ao equipamento, dilatação inadequada da pupila, iluminação inadequada da retina e a presença de opacidades nos meios oculares. Além disso, o aumento da expectativa de vida nas últimas décadas tem agravado ainda mais a situação.

Considerando essas informações, este trabalho apresentou o desenvolvimento de um algoritmo para segmentação automática de drusas em imagens de retinografia, utilizando técnicas básicas de processamento digital de imagens, visando auxiliar os profissionais na visualização da região. Tornando o processo de análise das imagens de retinografia e identificação da drusas e da DMRI mais rápido, preciso e eficaz.

Devido à ausência de rótulos e máscaras que detalhassem a localização, a quantidade e o tamanho das drusas no banco de dados STARE, foi necessário criar máscaras rotuladas manualmente, para validar os resultados obtidos pelo algoritmo desenvolvido. Essas máscaras foram elaboradas em dois cenários: uma contendo todas as drusas presentes na imagem, e outra focada apenas nas drusas localizadas na região central. Embora esse processo tenha caráter um subjetivo, foi fundamental para comparar os resultados do algoritmo com uma referência visual, permitindo verificar se as áreas segmentadas correspondiam corretamente às drusas rotuladas de forma manual.

O algoritmo desenvolvido apresentou elevados índices de acurácia e especificidade, atingindo 97,53% e 99,18%, respectivamente, evidenciando a eficácia em segmentar as drusas, duras e moles, nas imagens de retinografia. No entanto, os resultados de sensibilidade obtidos apresentaram desempenho inferior ao de outros algoritmos

utilizados como referência, pois, artefatos como o disco óptico (DO) e áreas de alta luminosidade interferiram na identificação das drusas, por possuírem intensidades semelhantes.

Além disso, em alguns casos, apesar das drusas terem sido segmentadas, a extração foi insuficiente. Isso ocorreu principalmente devido à diferença de intensidade entre os pixels do disco óptico, que apresentavam valores significativamente maiores, e as drusas não identificadas, que tinham intensidades mais baixas. Essa discrepância levou o algoritmo a separar esses elementos em clusters distintos.

A aplicação da máscara circular no pós-processamento resultou em um aprimoramento superior, aumentando a precisão ao isolar esses artefatos. Embora a máscara tenha apresentado limitações em imagens com o disco óptico centralizado e alta luminosidade na região central, o algoritmo segmentou as drusas de forma eficaz.

Essa estratégia de segmentação proposta pode ser utilizada de forma complementar na avaliação e acompanhamento da DMRI, proporcionando suporte aos profissionais de saúde na identificação precoce da doença. Além disso, contribui para o aprimoramento da análise visual das imagens, oferecendo uma ferramenta, acessível e de baixo custo de implementação.

6.1 TRABALHOS FUTUROS

Diante dos impactos da Degeneração Macular Relacionada a Idade (DMRI) e considerando os resultados obtidos através das técnicas de segmentação apresentadas neste trabalho, estudos futuros podem explorar aprimoramentos em diversas perspectivas. Uma delas se dá pelo desenvolvimento de algoritmos que minimizem o impacto de áreas com alta luminosidade nas imagens de retinografia, pois, evita que ocorra situações em que as drusas possam ficar “escondidas” atras dessas regiões, por apresentarem intensidades semelhantes, não sendo possível detectá–las. Além disso, métodos que possibilitem a detecção do disco óptico em diferentes ângulos das imagens mostram-se úteis, evitando confusões com as drusas devido aos níveis de intensidade semelhantes entre essas estruturas. Dessa forma, será possível aprimorar a precisão da segmentação em condições adversas.

Implementar modelos capazes de classificar o estágio da DMRI com base em características como tamanho, formato e quantidade das drusas, podendo assim gerar diagnóstico mais preciso e detalhados quanto ao avanço, estágios e gravidade da doença.

A utilização de *Convolutional neural network* (CNNs) também se apresenta como uma perspectiva promissora, permitindo refinar ainda mais a segmentação das drusas e reduzir as taxas de falsos positivos e negativos. Técnicas de *Machine Learning*, como *Support Vector Machines* (SVM), podem ser utilizadas para criar modelos robustos, fornecendo informações mais detalhadas sobre o progresso e a gravidade da doença.

Por fim, a combinação de técnicas de pré-processamento, como a remoção de artefatos com filtros adaptativos, aliada ao uso de modelos avançados de *Deep Learning* e métodos de classificação, pode resultar em um sistema mais preciso e eficaz para a segmentação de drusas e o diagnóstico da DMRI, proporcionando melhores ferramentas para monitoramento e acompanhamento contínuo da doença.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ALVES, D. **Desempenho De Retinografia Portátil Com Inteligência Artificial No Rastreio De Retinopatia Diabética Na Atenção Primária Em Saúde**. 2024. 64 p. Dissertação (Mestrado em pesquisa clínica) - Hospital de Clínicas de Porto Alegre, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2024.

BELLO, A., & SARABIA, M. **Retina: Degeneración Macular relacionada con la Edad: Conceptos Actuales.** Revista de la Facultad de Medicina, 25(2), 237-243.(2002)

BEAR, Mark F.; CONNORS, Barry W.; PARADISO, Michael **A. Neurociências: desvendando o sistema nervoso.** Artmed editora, 2017.

BOURNE, R. R. A. *et al.* **Causes of vision loss worldwide, 1990–2010: a systematic analysis**. The Lancet Global Health, v. 1, n. 6, p. e339–e349, dez. 2013.

BOWLING , BRAD. **Kanski Oftalmologia Clínica: Uma Abordagem Sistêmica**. 8th ed., Sydney - Australia, GEN Guanabara Koogan, p. 928, 2022.

BOYER, C. B. **História da matemática**. 3. ed. São Paulo: Blucher, 2019. 512 p.

CARVALHO, J. A. *et al.* **Perfil epidemiológico de pacientes com degeneração macular relacionada à idade.** Revista Brasileira de Oftalmologia, v. 82, 2023.

COHEN, J. *et al*. **Degeneração macular relacionada à idade: etiologia, fisiopatologia e avanços no diagnóstico**. <https://journalmbr.com.br/index.php/jmbr/article/view/35/19>. DOI: < https://doi.org/10.37039/1982.8551.20230061>. Acesso em: 26 dez. 2024.

DENG, Y. *et al.* **Age-related macular degeneration: Epidemiology, genetics, pathophysiology, diagnosis, and targeted therapy.** Genes & Diseases, v. 9, n. 1, p. 62–79, fev. 2021.

DUARTE, RITA S. **Degeneração macular relacionada com a idade (DMRI)**. 2010. 25 p. Relatório de Estágio (Mestrado em Optometria em Ciências da Visão) - Faculdade de Ciências da saúde, Universidade Da Beira Interior, Covilhã, 2010. Disponível em: <https://www.proquest.com/openview/ee1c4fd68ec676f782133c8ee5759b2c/1?pq-origsite=gscholar&cbl=2026366&diss=y>. Acesso em: 15 dez. 2024.

ELLIOTT, D. B. **Clinical procedures in primary eye care**. 5. ed. St. Louis: Elsevier, 2020. 336 p.

FABRE, M. *et al*. **Recent Advances in Age-Related Macular Degeneration Therapies.** Molecules (Basel, Switzerland), v. 27, n. 16, p. 5089, 2022. DOI:< 10.3390/molecules27165089> Disponível em: </ https://pmc.ncbi.nlm.nih.gov/articles/PMC9414333/>. Acesso em: 26 dez. 2024.

FANG, H. *et al*. **ADAM Challenge: Detecting Age-Related Macular Degeneration From Fundus Images.** IEEE Transactions on Medical Imaging, v. 41, n. 10, p. 2828–2847, 1 out. 2022. DOI 10.1109/TMI.2022.3172773. Disponível em: </ https://ieeexplore.ieee.org/document/9768802/>. Acesso em: 26 dez. 2024.

FLAXMAN, S. R. et al. Global causes of blindness and distance vision impairment 1990–2020: a systematic review and meta-analysis. **The Lancet Global Health**, v. 5, n. 12, p. e1221–e1234, dez. 2017. DOI: < 10.1016/S2214-109X(17)30393-5>. Disponível em: </ https://pubmed.ncbi.nlm.nih.gov/29032195//>. Acesso em: 26 dez. 2024.

GOBIRA, DR. M. **Como A Retinografia Pode Revelar Mais Do Que Problemas De Visão**. Disponível em: <https://blog.eyecarehealth.com.br/retinografia/>. Acesso em: 15 dez. 2024.

GONZALEZ, R. **Processamento Digital de Imagens**. 3. ed. São Paulo: Pearson Education, 2010. 672 p.

GUTTERRES, DANIEL M. M. **Proposta E Implementação De Uma Ferramenta Para Análise De Imagens De Retinografia Digital**. 2010. 105 p. Trabalho De Conclusão De Graduação (Graduação em Ciência da computação) , Universidade Federal do Rio Grande do Sul, Porto Alegre, 2010.

HALL, J. E. **Tratado de Fisiologia Médica**. 12. ed. Rio de Janeiro: Elsevier Editora Ltda., 2011. p. 1173.

HOOVER, A. **STARE Project: structured analysis of the retina**. Clemson University. Disponível em: <https://cecas.clemson.edu/~ahoover/stare/>. Acesso em: 28 dez. 2024. Base de dados.

HUANG, Y. *et al.* **Global, regional, and national burden of age-related macular degeneration, 1990–2019: an age-period-cohort analysis based on the Global Burden of Disease 2019 Study**. Frontiers in Public Health, v. 12, 22 out. 2024. DOI: </3389/fpubh.2024.1486168/> Disponível em: </ https:/ https://pubmed.ncbi.nlm.nih.gov/39502824/ />. Acesso em: 26 dez. 2024.

INTERLENGHI M. *et al.* **A Radiomic-Based Machine Learning System to Diagnose Age-Related Macular Degeneration from Ultra-Widefield Fundus Retinography.** v. 13, n. 18, p. 2965–2965, 15 set. 2023. DOI: < 10.3390/diagnostics13182965 >. Disponível em: </ https://pubmed.ncbi.nlm.nih.gov/37761333/>. Acesso em: 26 dez. 2024.

JAN, J. **Medical image processing, reconstruction and analysis concepts and methods**. 2. ed. New York: CRC Press, 2019. 598 p.

KASHANI, A. H. et al. Past, present and future role of retinal imaging in neurodegenerative disease. **Progress in Retinal and Eye Research**, v. 83, 100938, 1 jul. 2021. DOI: <10.1016/j.preteyeres.2020.100938>. Disponível em: </ https://pubmed.ncbi.nlm.nih.gov/33460813/>. Acesso em: 26 dez. 2024.

KHALID, S. *et al*. Automated diagnosis system for age-related macular degeneration using hybrid features set from fundus images**. International Journal of Imaging Systems and Technology**, v. 31, n. 1, p. 236–252, 26 jun. 2020. DOI: < https://doi.org/10.1002/ima.22456>. Disponível em: </ https:// https://onlinelibrary.wiley.com/doi/abs/10.1002/ima.22456/>. Acesso em: 26 dez. 2024.

KIM, Y. J.; KIM, K. G. Automated Segmentation Methods of Drusen to Diagnose Age-Related Macular Degeneration Screening in Retinal Images. **Computational and**

Mathematical Methods in Medicine, v. 2018, p. 1–8, 2018. DOI: < 10.1155/2018/6084798 >. Disponível em: </ https:// https:// https://pubmed.ncbi.nlm.nih.gov/29721037//>. Acesso em: 26 dez. 2024.

LANDRY, D. A. Retinal imaging: past, present, and future. **Insight (American Society of Ophthalmic Registered Nurses)**, v. 41, n. 2, p. 5–11, 35; quiz 12, 2016.

MATTE, M. KUCHAR *et al*. **Revisão de estratégias para a aceleração do algoritmo k-Means**. Anais do XV WCF, v. 6, p. 1–6, 2019.

MATHWORKS. **Convertir a escala de grises.** Disponível em: <https://www.mathworks.com/help/matlab/ref/rgb2gray.html>. Acesso em: 29 dez. 2024.

MARQUES, O. F.; VIEIRA, H. N. **Processamento Digital de Imagens, Rio de Janeiro: Brasport**, 1999. ISBN 8574520098.

MEIRELLES, R. **RETINA**. 110. ed. São Paulo: Dois Editorial, 2019. 32 p.

MINISTÉRIO DA SAÚDE. **Degeneração Macular Relacionada à Idade (forma neovascular)**. Brasília, DF: Conitec, ago. 2022. Disponível em: < https://www.gov.br/conitec/pt-br/midias/consultas/relatorios/2022/20220830_relatorio_pcdt_dmri_cp54.pdf>. Acesso em: 23 dez. 2024.

MITTAL, D.; KUMARI, K. **Automated detection and segmentation of drusen in retinal fundus images.** Computers & Electrical Engineering, v. 47, p. 82–95, out. 2015.

MOLER, C. **A Brief History of MATLAB**. 2018. Disponível em: <https://www.mathworks.com/company/technical-articles/a-brief-history-of-matlab.html>. Acesso em: 27 dez. 2024.

MONTEIRO, M.; SARMENTO, A. A HW/SW System to Detect Druses in Retinal Fundus Image for the Diagnostic of Age-Related Macular Degeneration. **2020 IEEE 33rd International Symposium on Computer-Based Medical Systems (CBMS)**, p. 297–302, jul. 2020.

MORANO, J. *et al*. I**mproving AMD Diagnosis by the Simultaneous Identification of Associated Retinal Lesions.** Lecture Notes in Computer Science, v. vol 13231, n. ICIAP 2022, p. 148–159, 2022.

MUCHUCHUTI, T.; VIRIRI, S. **Retinal disease detection using deep learning techniques: a review. J. Imaging,** v. 9, n. 84, p. 1-38, 2023.DOI: <https://doi.org/10.3390/jimaging9040084>. Disponível em: </ https://www.mdpi.com/2313-433X/9/4/84/> Acesso em: 27 dez. 2024.

NATIONAL EYE INSTITUTE. **Age-Related Macular Degeneration**. 2021. Disponível em: </https://www.nei.nih.gov/learn-about-eye-health/eye-conditions-and-diseases/age-related-macular-degeneration/>. Acesso em: 10 dez. 2024.

NASCIMENTO-JÚNIOR, B. J. DO. **Anatomia humana sistemática básica**. 1. ed. Petrolina - PE: UNIVASF, 2020. 228 p.

NGUYEN, K. H.; PATEL, B. C.; TADI, P. **Anatomy, Head and Neck, Eye Retina**. 2023. Disponível em: <https://www.ncbi.nlm.nih.gov/books/NBK542332/>. Acesso em: 10 dez. 2024.

PARANHOS, F. R. L.; COSTA, R. A.; MEIRELLES, R.; SIMÕES, R. Degeneração macular relacionada à idade. ***Revista da Associação Médica Brasileira***, São Paulo, v. 59, n. 2, p. 106-111, abr. 2011.

PINA, G. C. *et al.* Degeneração macular relacionada à idade: uma visão geral e atualizações. **Brazilian Journal of Development**, v. 8, n. 11, p. 71394–71408, 4 nov. 2022.

QUEIROZ, J. E. R.; GOMES, H. M. Introdução ao processamento digital de imagens. **Revista RITA: instruções para preparação de documentos em Word,** RITA, v. 8, n. 1, 2001.

RÊGO, S. M. S. DE F. **Degenerescência macular relacionada com a idade**. 2012. 80 p. Dissertação (Mestrado em Medicina) - Universidade da Beira Interior, Covilhã, 2012.

RETINA INTERNATIONAL. **AMD Diagnosis.** 2021. Disponível em: <https://retina-international.org/amd-diagnosis/>. Acesso em: 15 dez. 2024.

RIBEIRO, M. A. RUFINO. **Rede Social Gamer com modelagem do algoritmo K-means para indicação de novas amizades**. 2022. 61 p. Trabalho de conclusão de curso (Graduação em Sistemas de Informação) - Faculdade de Computação, Universidade Federal de Uberlândia, Monte Carmelo, 2022.

RIBEIRO, T. *et al.* Análise das características da Degeneração Macular Relacionada à Idade. **Revista Eletrônica Acervo Saúde**, v. 23, n. 4, p. e12810–e12810, 30 abr. 2023.

RODRIGUES, A. F. SIMÕES. **Imagem de fundo ocular: Análise comparativa de técnicas e de novas tecnologias no diagnóstico oftalmológico da retina–Aplicação Clínica**. 2016. 123 p. Dissertação (Mestrado em Engenharia Biomédica) – Faculdade de Ciências e Tecnologia, Universidade de Coimbra, Portugal, 2016.

RUSS, J. C.; NEAL, F. B. ***The image processing handbook***. 7. ed. Boca Raton: CRC Press, 2018. 1.053 p.

SAINE, P. J. **Ophthalmic photography: a textbook of fundus photography, angiography, and electronic imaging: Saine, Patrick J : Free Download, Borrow, and Streaming : Internet Archive**. Boston: Butterworth-Heinemann, 1996.

SCURI, Antonio Escaño. **Fundamentos da imagem digital**. Rio de Janeiro, p. 16-18, 2002.

SILVA, A. M. M.; PATROCÍNIO, A. C.; SCHIABEL, H. Processamento e Análise de Imagens Médicas**. Revista Brasileira de Física Médica**, v. 13, n. 1, p. 34, 1 set. 2019.

SODRÉ S. L. **Custos e benefícios do compartilhamento do bevacizumabe para o tratamento das doenças vasculares retinianas**. 2019. 117 p. Dissertação (Mestrado em concentração Oftalmologica) - Faculdade de Ciências Médicas, Universidade Estadual de Campinas, Campinas, 2019.

SOLOMON, C.; BRECKON, T. ***Fundamentals of digital image processing: a practical approach with examples in MATLAB***. Hoboken: Wiley-Blackwell, 2011. 344 p.

STANDRING, S. **Gray's Anatomy The Anatomical Basis of Clinical Practice**. 41. ed. London, UK: Elsevier, 2015. 1.376 p.

STOER, J. **Introduction to Numerical Analysis**. 3rd ed. New York: Springer, 2002. 688 p.

TORRES, R. J. DE A.; FERREIRA, A. L. DOS A. **Degeneração macular relacionada à idade: um panorama geral**. Rev. bras.oftalmol**.**, v. 80, n. 5, p. –, 29 set. 2021.

VERAS, R. DE M. S. **Detecção E Segmentação De Estruturas Em Imagens Médicas De Retina**. 2014. 86 p. Tese (Doutorado em Engenharia de Teleinformática) - Universidade Federal do Ceará, Fortaleza, 2014.

WASEEM, S.; USMAN, M. A.; BILAL, A. A. **Drusen detection from colored fundus images for diagnosis of age-related macular degeneration**. *IEEE Xplore*, Colombo, Sri Lanka, 2014. DOI: <10.1109/ICIAFS.2014.7069581>. Disponível em: </https://ieeexplore.ieee.org/document/7069581/>. Acesso em: 20 dez. 2024.

WONG, W. L. *et al.* Global prevalence of age-related macular degeneration and disease burden projection for 2020 and 2040: a systematic review and meta-analysis. **The Lancet Global Health**, v. 2, n. 2, p. e106–e116, fev. 2014.

YELLAPRAGADA, B. *et al.* Self-supervised feature learning and phenotyping for assessing age-related macular degeneration using retinal fundus images**. Ophthalmology Retina**, jul. 2021. DOI: < 10.1016/j.oret.2021.06.010 >. Disponível em: </ https://pubmed.ncbi.nlm.nih.gov/34217854/Acesso em: 20 dez. 2024.

ZHU, Z. et al. Retinal age gap as a predictive biomarker for mortality risk. **British Journal of Ophthalmology**, p. bjophthalmol-2021-319807, 18 jan. 2022.