



Ana Emília Malvino Ferreira da Costa

**Detecção Automática de Exsudatos e Microaneurismas
em Imagens de Retinopatia Diabética Utilizando o
Algoritmo Bioinspirado na Colônia Artificial de
Abelhas e Processamento Digital de Imagens**

João Pessoa - PB

Março de 2019



Ana Emília Malvino Ferreira da Costa

**Detecção Automática de Exsudatos e Microaneurismas
em Imagens de Retinopatia Diabética Utilizando o
Algoritmo Bioinspirado na Colônia Artificial de
Abelhas e Processamento Digital de Imagens**

Dissertação de Mestrado submetido ao Programa de Pós-Graduação em Engenharia Elétrica do Instituto Federal da Paraíba, como requisito necessário à obtenção do grau de Mestre em Ciências no Domínio da Engenharia Elétrica.

Área de Concentração: Processamento de Sinais.

Orientador: Carlos Danilo Miranda Regis, Prof. Dr.

João Pessoa - PB, Março de 2019

©Ana Emília Malvino Ferreira da Costa - ana.emilia.malvino@hotmail.com.

Dados Internacionais de Catalogação na Publicação (CIP)

Biblioteca Nilo Peçanha do IFPB, *campus* João Pessoa

C837d Costa, Ana Emília Malvino Ferreira da.

Detecção automática de exsudatos e microaneurismas em imagens de retinopatia diabética utilizando o algoritmo bioinspirado na colônia artificial de abelhas e processamento digital de imagens / Ana Emília Malvino Ferreira da Costa. - 2019.

71 f.: il.

Dissertação (Mestrado - Engenharia Elétrica) - Instituto Federal da Paraíba / Programa de Pós-Graduação em Engenharia Elétrica, 2019)

Orientador: Carlos Danilo Miranda Regis

1. Algoritmo bioinspirado - colônia artificial de abelhas. 2. Processamento digital de imagens - retinopatia diabética. 3. Microaneurismas. I. Título.

CDU 004.021(043)

Lucrécia Camilo de Lima

Bibliotecária

CRB 15/132

Instituto Federal de Educação da Paraíba
Programa de Pós-Graduação em Engenharia Elétrica

Detecção Automática de Exsudatos e Microaneurismas em Imagens de Retinopatia Diabética Utilizando o Algoritmo Bioinspirado na Colônia Artificial de Abelhas e Processamento Digital de Imagens

Ana Emília Malvino Ferreira da Costa

Dissertação de Mestrado defendida e aprovada em 22/03/19.

Banca examinadora:



Prof. Carlos Danilo Miranda Regis, Dr.

Orientador (IFPB)



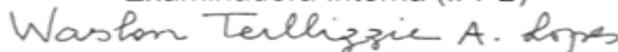
Prof., Luiz Guedes Caldeira Dr.

Examinador Externo (IFPB)



Prof. Suzete Élide Nóbrega Correia, Dr.

Examinadora Interna (IFPB)



Prof. Waslon Terllizzie Araújo Lopes, Dr.

Examinador Externo (UFPB)

João Pessoa, Paraíba, Brasil

22 de Março de 2019

@Ana Emília Malvino Ferreira da Costa



Agradecimentos

Primeiro de tudo, gostaria de agradecer à Deus por me guiar, iluminar e me dar tranquilidade para seguir em frente com os meus objetivos e não desanimar com as dificuldades. Agradeço a Ele também por me permitir errar, aprender e crescer como pessoa. Ao Prof. Dr. Carlos Danilo Miranda Regis, pela orientação, competência, profissionalismo e dedicação tão importantes.

Aos membros da banca examinadora, Prof^a. Dr^a. Suzete Élide Nóbrega Correia, Prof. Dr. Luiz Guedes Caldeira e Prof. Dr. Waslon Terlizze Araújo Lopes, que tão gentilmente aceitaram participar e colaborar com esta dissertação.

À minha família, cunhada e a minha sogra, por apoiarem e compreenderem o meu distanciamento durante toda a semana, às vezes até meses.

À minha mãe, Kátia Cilene, pelo incentivo, companheirismo, amizade, caridade, dedicação, abnegação e compreensão. Sinto-me orgulhosa e privilegiada por ter uma mãe tão especial. E à minha irmã querida, Anna Raquel, sempre pronta a me apoiar em tudo.

À meu amado esposo Erich Vinicius, por todo amor, carinho, compreensão e apoio em tantos momentos difíceis desta caminhada. Obrigado por permanecer ao meu lado, mesmo sem os carinhos rotineiros, sem a atenção devida e depois de tantos momentos de lazer perdidos. Obrigada pelo presente de cada dia, pelo seu sorriso e por saber me fazer feliz.

À meu príncipe Miguel, por todo amor que você sempre me deu. Inúmeras foram as vezes que, você pediste para eu ficar mesmo sabendo que tinha que viajar. Todo o esforço e dedicação que tive durante esta jornada acadêmica foi por você meu filho.

Ao IFPB pelo aporte financeiro, sem o qual seria impossível a realização deste trabalho.

Resumo

O diagnóstico da retinopatia diabética, em imagens do fundo do olho, impulsionou o desenvolvimento de algoritmos de processamento que fossem capazes de identificar e classificar patologias automaticamente. As técnicas de processamento digital de imagens, aplicadas à medicina, facilitam a visualização e identificação de patologias a partir de minimização de artefatos indesejáveis nas imagens. O objetivo do presente trabalho consiste em implementar pelo método baseado na colônia artificial de abelhas (*Artificial Bee Colony* - ABC), para a detecção de exsudatos, e o uso de técnicas de processamento digital de imagens para facilitar nos processos de detecção e classificação das microaneurismas. Como sinais de entrada para os algoritmos, foram utilizadas as imagens do banco de dados da *Diaretdb1*. Técnicas de pré-processamento foram utilizadas para realizar a exclusão do disco óptico (projeção luminosa decorrente dos exames de fundoscopia), e uma máscara foi proposta para encontrar nas imagens a patologia, com base na forma e tamanho da mesma. Para a avaliação dos algoritmos desenvolvidos foram utilizadas as taxas de sensibilidade, especificidade e acurácia das imagens. Na detecção dos exsudatos os valores coletados após o pós-processamento foram 85% de sensibilidade, 92% de especificidade e 96% de acurácia. Na detecção e classificação das microaneurismas, os testes retornaram 75% de sensibilidade, 99% de especificidade e 98% de acurácia. Conforme as imagens resultantes dos processos de detecção, foram identificados 52 pacientes com a presença de exsudatos em comparação com o banco de dados que diagnosticaram 48 pacientes com a doença. O algoritmo de classificação detectou a evidência de microaneurismas em 75 pacientes e o banco de dados diagnosticou a patologia em 71.

Palavras-Chave: Algoritmo Bioinspirado na Colônia Artificial de Abelhas, Fundoscopia, Processamento Digital de Imagens, Retinopatia Diabética.

Abstract

The diagnosis of diabetic retinopathy in the fundus of the eye has led to the development of processing algorithms capable of identifying and classifying pathologies automatically. The techniques of digital image processing, applied to medicine, facilitate the visualization and identification of pathologies by minimizing undesirable artifacts in the images. The bioinspired algorithms, in colonies or swarms are executed in medical images with the purpose of selecting characteristics referring to pathologies. The objective of the present work is to implement by the artificial bee colony method (ABC), for the detection of exudates, and the use of digital image processing techniques to facilitate the detection and classification of microaneurysms . As input signals to the algorithms, images from the Diaretddb1 database were used. Pre-processing techniques were used to perform the optical disc exclusion (light projection resulting from funduscopy examinations), and a mask was proposed to find in the images the pathology, based on the shape and size of the same.

Keywords: Bioinspiratory Algorithm in Artificial Bee Colony, Fundoscopy, Digital Image Processing, Diabetic Retinopathy.

Lista de Siglas

ABC - <i>Artificial Bee Colony</i>	Colônia artificial de abelhas
ACO - <i>Ant Colony Optimization</i>	Otimização por colônia de formigas
AFS - <i>Artificial Fish Swarm</i>	Enxame artificial de peixes
CAD - <i>Computer-Aided Diagnosis</i>	Diagnóstico auxiliado por computador
DM - <i>Diabetes Mellitus</i>	
DWT - <i>Discrete Wavelet Transform</i>	Transformada discreta de Wavelet
FFNN - <i>Feedforward Neural Network</i>	Rede neural feedforward
HSI - <i>Hue, Saturation and Intensity</i>	Matiz, saturação e intensidade
PSO - <i>Particle Swarm Optimization</i>	Otimização por enxame de partículas
RGB - <i>Red, Green and Blue</i>	Vermelho, verde e azul
TH - <i>Hough Transform</i>	Transformada de Hough

Lista de Símbolos

x	Coordenada do eixo horizontal
y	Coordenada do eixo vertical
(x, y)	Coordenadas espaciais
$f(x, y)$	Representação de uma imagem
$g(x, y)$	Função de saída de uma imagem
T	Operador de transformação
\ominus	Operador de erosão
\oplus	Operador de dilatação
ϕ_{ij}	Posição do <i>pixel</i>
\circ	Operador de abertura
\bullet	Operador de fechamento
σ	Desvio padrão
∇f	Operador gradiente da imagem f
d_x	Derivada em relação ao eixo x
d_y	Derivada em relação ao eixo y
x_{ij}	Fonte inicial
x_{ik}	Fonte aleatória

Lista de Figuras

1	Estruturas oculares.	20
2	Retina humana.	22
3	Doenças oculares.	23
4	Início da retinopatia diabética, microaneurismas.	24
5	Evolução da retinopatia diabética não proliferativa.	25
6	Retinopatia diabética proliferativa.	25
7	Vizinhança 3×3 ao redor do ponto (x, y) em uma imagem no domínio espacial.	27
8	Conjuntos estruturantes.	28
9	Representação de conjuntos estruturantes na forma de uma matriz.	29
10	Operação de erosão do conjunto A pelo conjunto estruturante circular B	30
11	Operação de dilatação do conjunto A pelo conjunto estruturante circular B	31
12	Representação de uma operação de abertura.	32
13	Representação de uma operação de fechamento.	33
14	Representação de uma implementação da transformada de Hough.	35
15	Representação do espaço de Hough.	35
16	Acumulador de Hough.	36
17	Fluxograma do algoritmo ABC.	38
18	Regras para a implementação do algoritmo da colônia artificial de abelhas.	40
19	Inicialização da colônia de abelhas.	41
20	Exploração dos <i>pixels</i> vizinhos à fonte de alimento inicial.	42
21	Representação de uma implementação da entropia de Kápur.	43
22	Diagnósticos referentes a imagem 015 do banco de dados da <i>Diaretdb1</i>	46
23	Imagens originais do banco de dados.	47
24	Resultado do pré-processamento.	48
25	Resultado do algoritmo das abelhas.	49
26	Resultado do pós-processamento aplicado na detecção dos exsudatos.	50
27	Comparação do banco de dados, com o último teste realizado com o algoritmo ABC.	52

28	Resultado do pré-processamento aplicado na detecção das microaneurismas.	53
29	Marcação dos artefatos indesejáveis.	53
30	Binarização da imagem com a marcação de artefatos.	54
31	Multiplicação entre a máscara e as imagens.	55
32	Modelo da microaneurisma, ampliada.	55
33	Comparação do banco de dados com o resultado da detecção das microaneurismas.	56
34	Resultado do pós-processamento aplicado na detecção dos exsudatos.	57
35	Exemplos das imagens classificadas quanto a presença de microaneurismas.	63

Lista de Tabelas

2	Resumo do estado da arte.	19
3	Resumo dos efeitos causados pelas doenças oculares.	23
4	Parâmetros utilizados para implementação da TH em imagens.	48
5	Resultados da detecção dos <i>pixels</i> que representam os exsudatos quanto a região de diagnóstico dos especialistas.	60
6	Comparação da detecção dos exsudatos com outros autores.	61
7	Classificação das imagens quanto à presença ou não de exsudatos.	61
8	Resultados da detecção dos <i>pixels</i> que representam as microaneurismas quanto a região de diagnóstico dos especialistas.	62
9	Comparação da detecção das microaneurismas com outros autores.	62
10	Classificação das imagens quanto à presença ou não de microaneurismas. . .	64

Sumário

1	Introdução	14
1.1	Motivação	15
1.2	Objetivo Geral	16
1.2.1	Objetivos Específicos	16
1.3	Estado da Arte	17
1.4	Estrutura do Texto	18
2	Olho Humano	20
2.1	Estrutura Ocular	20
2.2	Retina	21
2.3	Doenças Oculares	22
2.4	Retinopatia Diabética	23
3	Processamento Digital de Imagens	26
3.1	Imagem	26
3.2	Filtragem no Domínio Espacial	26
3.2.1	Filtro Espacial de Suavização	27
3.3	Morfologia Matemática	28
3.3.1	Erosão e Dilatação	29
3.3.2	Abertura e Fechamento	31
3.4	Transformada de Hough	33
3.4.1	Transformada Circular de Hough	33
4	Algoritmo Bioinspirado na Colônia Artificial de Abelhas	37
4.1	Abelhas Empregadas	40
4.2	Abelhas Espectadoras	43
4.3	Abelhas Escoteiras	44
5	Metodologia	45
5.1	Banco de Dados	45

5.2	Detecção dos exsudatos	45
5.2.1	Pré-processamento	46
5.2.2	Implementação do algoritmo ABC	48
5.2.3	Pós-processamento	50
5.3	Detecção das microaneurismas	51
5.3.1	Pré-processamento	51
5.3.2	Processamento	54
5.3.3	Pós-processamento	55
5.4	Validação dos algoritmos de detecção de patologias	57
6	Resultados Experimentais	59
6.1	Detecção dos exsudatos	59
6.2	Detecção das microaneurismas	61
7	Conclusão	65
7.1	Trabalhos futuros	66
A	Apêndice	67

1 Introdução

Os sistemas de diagnósticos auxiliados por computador (*Computer-Aided Diagnosis-CAD*), são sistemas muitas vezes acoplados à equipamentos médicos, que auxiliam os especialistas em medicina na tomada de decisão a respeito de um diagnóstico, como exemplos podem ser citados os exames por imagens de tomografia, raios-x, fundoscopia e a ultrassonografia (Nunes, 2006). Nesse ramo destaca-se o processamento digital de imagens médicas que tem por objetivo fornecer ferramentas que modificam as imagens para facilitar a identificação e análise de patologias no corpo humano (Trigueiro, 2015).

A retinopatia diabética, também denominada de lesões em imagens da retina, quando detectada automaticamente pode fornecer informações úteis que ajudarão na identificação de possíveis doenças que ainda não causam sintomas, em sua fase inicial (Bagesteiro, 2013). Além de patologias oculares, como o glaucoma e a catarata, doenças sistêmicas como a hipertensão e a diabetes *Mellitus* (DM) podem ser diagnosticadas a partir da análise das imagens da retina. Isto é possível, pelo fato do olho ser o único órgão do corpo que possibilita a análise de nervos, veias e artérias sem métodos invasivos (Kurocama *et al.*, 2018).

Devido à falta de informação, ou pelo fato da população não ter ciência da importância do exame de fundoscopia, diversas doenças que afetam os nervos, as veias e artérias do nosso corpo não são diagnosticadas precocemente, o qual acarreta na maioria dos casos a cegueira de forma irreversível, o que acontece em pacientes com a DM não controlada.

Segundo Tortora & Derrickson (2016) o exame de fundoscopia permite a identificação de anormalidades na retina devido alterações no corpo que afetam os vasos sanguíneos. O aparelho responsável pela realização do exame, armazena as imagens geradas durante o processo, auxiliando os especialistas em oftalmologia na solução de um diagnóstico precoce, bem como no acompanhamento de eventuais anomalias, e evolução de patologias. O exame de fundoscopia é realizado por um médico com o auxílio do equipamento denominado de oftalmoscópio. Este aparelho consiste em emitir um feixe luminoso na pupila, ou seja, na parte central posterior do olho, para que possa ser visualizado o fundo ocular. As estruturas internas da retina que podem ser observadas neste tipo de exame são o nervo óptico, veias, artérias além de eventuais patologias (Polyak, 1941).

Considerando que, a Imageologia é uma ferramenta de auxílio médico, a imagem resultante do exame tem que possuir uma maior nitidez das estruturas presentes na retina. Ao contrário, as superfícies de interesse podem não ser alcançadas, acarretando em um diagnóstico falso negativo, em que o exame resultante não contém evidências de anomalias, quando na verdade existe. No entanto, as imagens da retina captadas por câmaras de fundoscopia podem conter artefatos que impliquem na sua inutilização ou conduzir a diagnósticos incorretos, especialmente quando as patologias são detectadas por métodos automáticos (Trigueiro, 2015).

Na literatura, alguns autores optam por excluir o disco óptico nos primeiros passos realizados em tratamento de imagens da retina, utilizando técnicas de processamento digital de imagens para minimizar ruídos provenientes e realçar estruturas de interesse (Zhang *et al.*, 2014). Juntamente com as técnicas de processamento digital de imagens, os algoritmos bioinspirados em colônias ou enxames vêm sendo usados para seleção de características em diversas áreas de conhecimento. Em imagens médicas, alguns algoritmos empregados foram a colônia artificial de abelhas (*Artificial Bee Colony* - ABC) implementado por Zhang *et al.* (2011) na classificação de patologias em imagens de ressonância magnética, e a otimização por colônia de formigas (*Ant Colony Optimization*- ACO) implementado por Aguiar (2017) para avaliação de Acidente Vascular Cerebral - AVC em imagens de tomografia computadorizada.

1.1 Motivação

As técnicas de otimização baseadas em colônias ou enxames surgiram a partir da ideia de reproduzir em computador a forma pela qual as sociedades coletivas processam o conhecimento (Karaboga & Basturk, 2007). Assim como todas as outras abordagens de inteligência de colônias, o *Artificial Bee Colony* - ABC baseia-se em uma população de indivíduos capazes de interagir entre si e com o meio ambiente.

O algoritmo ABC utiliza os princípios de uma teoria sociocognitiva muito simples: 1) cada indivíduo de uma população possui sua própria experiência e é capaz de avaliar a qualidade desta experiência; 2) como há interação social entre os indivíduos, eles também possuem conhecimentos sobre os desempenhos de seus vizinhos.

O algoritmo ABC é tão simples quanto os demais algoritmos que se baseiam na oti-

mização de enxames, como por exemplo, a otimização por enxame de partículas (*Particle Swarm Optimization* - PSO) e a evolução diferencial (*Differential Evolution* - DE). Uma das vantagens do algoritmo ABC em relação à outros algoritmos bioinspirados é a flexibilidade no ajuste de parâmetros de controle comuns, como o tamanho da colônia de abelhas e o número máximo de ciclos.

A contribuição deste trabalho consiste em realizar a detecção da retinopatia diabética, através da segmentação de imagens fundoscópicas, utilizando o algoritmo ABC. Outra contribuição deste trabalho é a identificação e classificação das microaneurismas com o auxílio de técnicas de processamento digital de imagens.

1.2 Objetivo Geral

O objetivo deste trabalho consiste em desenvolver algoritmos baseado na colônia artificial de abelhas (*Artificial Bee Colony* - ABC) para a detecção dos exsudatos e a utilização de técnicas de processamento digital de imagens para a detecção e classificação das microaneurismas em imagens de retinopatia diabética.

1.2.1 Objetivos Específicos

A seguir estão listados os objetivos específicos deste trabalho.

- Estudar os aspectos teóricos referentes à retinopatia diabética;
- Estudar e implementar algoritmos de processamento digital de imagens como forma de pré-processar as imagens e realizar a detecção das microaneurismas;
- Estudar e implementar o algoritmo bioinspirado na colônia artificial de abelhas para a identificação dos exsudatos;
- Avaliar o desempenho dos algoritmos implementados tanto para a identificação dos exsudatos quanto para as microaneurismas.

1.3 Estado da Arte

Nesta seção serão apresentados trabalhos que foram realizados para detecção de patologias em imagens fundoscópicas, que utilizam técnicas de processamento digital de imagens, assim como trabalhos que implementam algoritmos de otimização para segmentação de imagens.

Abràmoff *et al.* (2010) desenvolveram um algoritmo para realizar a identificação de microaneurismas. O diferencial de Abràmoff *et al.* (2010) é a utilização de descritores de alta frequência, como a rede neural FFNN (*FeedForward Neural Network*), para realizar a identificação da anomalia. As microaneurismas afetam a suavização ou continuidade das imagens no tecido retiniano. Para avaliar o desempenho dos descritores, foram realizadas a análise da sensibilidade, especificidade e acurácia das imagens, que foram 90%, 47% e 43%, respectivamente.

Em Trigueiro (2015) foi desenvolvido um algoritmo automatizado para detecção dos exsudatos aplicando as técnicas de processamento digital de imagens. O autor implementou as técnicas de morfologia matemática, segmentação de imagens e também a transformada circular de Hough, para realizar o realce de estruturas internas oculares, evidenciando e identificando os exsudatos e o disco óptico. No trabalho, o autor ainda converteu as imagens no espaço de cor RGB (*Red, Green e Blue*) para HSI (*Hue, Saturation e Intensity*), realizando a comparação das imagens resultantes com o banco de dados da *Diaretdb1*. O autor validou seu algoritmo de detecção através da taxa de sensibilidade, obtendo aproximadamente 82% de acerto.

No trabalho de Rosas-Romero *et al.* (2015), foi realizada uma detecção de microaneurismas aplicando técnicas de processamento de imagens. A redução de intensidade não uniforme, implementada, foi realizada pela equalização das mesmas em escala de cinza, utilizando a transformada de Bottom-Hat para extrair detalhes relevantes, assim como o uso da binarização das imagens resultantes dos processos anteriores. O algoritmo de detecção foi avaliado pelo mesmo método de Trigueiro (2015), alcançando aproximadamente 92% de sensibilidade no algoritmo.

Hassanien *et al.* (2015) realizaram a segmentação de vasos sanguíneos da retina através da otimização pelo algoritmo ABC em conjunto com a função de adequação de

aglomerados *Fuzzy*, encontrando os maiores vasos. O algoritmo é validado empregando dois bancos de dados, obtendo 70% de sensibilidade, 97% de especificidade e 93% de acurácia.

Os autores Tan *et al.* (2017), implementaram uma rede neural convolutiva, de 10 camadas para realizar a segmentação e detecção dos exsudatos, hemorragias e microaneurismas, em imagens fundoscópicas. A validação do algoritmo foi realizada a partir das taxas de sensibilidade e especificidade, obtendo 87% 71% respectivamente.

No trabalho de Adalarasan & Malathi (2018), a extração do canal verde da imagem foi utilizada para realizar os ajustes de filtros adaptativos, a fim de detectar características como, microaneurismas, disco óptico, exsudatos e vasos retinianos. O algoritmo desenvolvido foi baseado na otimização de biogeografia, para classificar os *pixels* como parte ou não do objeto extraído. A avaliação quantitativa do algoritmo de segmentação foi realizada, através do método de sensibilidade dos *pixels*, apresentando cerca de 75% de precisão.

Na Tabela 2, é apresentado um resumo acerca do estado da arte, contendo metodologia e resultados dos autores citados neste capítulo.

1.4 Estrutura do Texto

No Capítulo 2 é abordado uma visão geral da fisiologia do olho humano, apresentadas as patologias oculares, com ênfase na retinopatia diabética. No Capítulo 3 são descritos diversos tipos de técnicas de processamento digital de imagens, que auxiliarão no desenvolvimento do projeto. No Capítulo 4 é discutido o algoritmo bioinspirado na colônia artificial de abelhas, implementado para realizar a detecção dos exsudatos. No Capítulo 5 são descritos os métodos utilizados para implementação e desenvolvimento dos algoritmos propostos neste trabalho. A apresentação e análise dos resultados estão no Capítulo 6. Por fim, as conclusões e sugestões para trabalhos futuros são apresentadas no Capítulo 7.

Tabela 2: Resumo do estado da arte.

Autoria	Metodologia	Resultados e Conclusões
Abràmoff (2010)	Detecção: Microaneurismas. - Rede Neural FFNN - Testes de diagnósticos	Sensibilidade: 90% Especificidade: 47% Acurácia: 43%
Trigueiro (2015)	Detecção: Exsudatos. - Transformada de Hough - Conversão no espaço de cor RGB-HSI.	Sensibilidade: 82%
Rosas-Romero et al. (2015)	Detecção: Microaneurismas. - Equalização do histograma - Transformada de Bottom-Hat	Sensibilidade: 92% Especificidade: 93% Acurácia: 95%
Hassaneien et al. (2015)	Detecção: Vasos. - Algoritmo ABC - <i>Fuzzy</i>	Sensibilidade: 70% Especificidade: 97% Acurácia: 93%
Tan et al. (2017)	Detecção: Exsudatos, Hemorragias e Microaneurismas. - Rede Neural	Sensibilidade: 87% Especificidade: 71%
Adalarasan e Malathi (2018)	Detecção: Microaneurismas, Exsudatos e Vasos. - Extração do canal verde - Filtros adaptativos - Computação biogeográfica	Sensibilidade: 75%

2 Olho Humano

Neste capítulo será abordado uma visão geral da fisiologia do olho humano, apresentando os vícios de refração mais comuns e algumas patologias oculares, com ênfase na retinopatia diabética.

2.1 Estrutura Ocular

O olho humano é considerado um sensor que atua em conjunto com o cérebro, captando imagens (Saba & Epiphonio, 2001). Para Costanzo (2011) o olho é responsável pelo sistema visual, o qual detecta e interpreta estímulos luminosos, correspondente a ondas eletromagnéticas. Além de enxergar, o olho humano possibilita a análise objetiva, sem métodos invasivos de nervos, veias e artérias.

A parede do olho humano é composta por três camadas concêntricas: a camada externa, a camada média e a interna (Costanzo, 2011), conforme a ilustração da Figura 2.1.

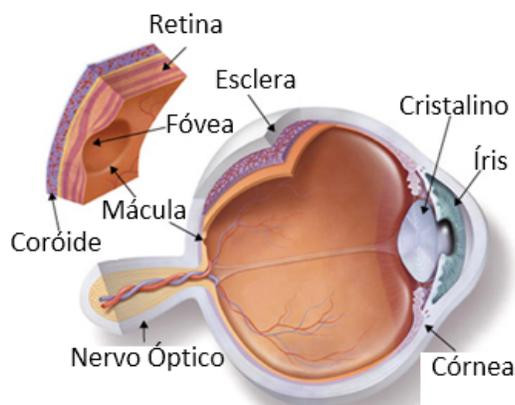


Figura 1: Estruturas oculares.
Fonte: Adaptado de (Costanzo, 2011).

Na camada externa, inclui a esclera, responsável por proteger o globo ocular, tornando-se transparente em sua porção anterior, formando a córnea. Na camada média, localiza-se a coróide, que contém vasos sanguíneos que nutrem as estruturas oculares. E na camada interna, encontra-se a retina, caracterizada pela camada complexa, que contém fotorreceptores e comunicações neurais (Aniche, 2009).

A esclera, é o nome da capa externa fibrosa, branca e rígida que envolve o olho, con-

tinuando com a córnea, tornando a estrutura que dá forma ao globo ocular. A córnea é a primeira estrutura do olho que a luz atinge. A córnea se constitui de cinco camadas de tecido transparente e resistente. A camada mais externa, o Epitélio, possui uma capacidade regenerativa muito grande e se recupera rapidamente de lesões superficiais. As quatro camadas seguintes, mais internas, são que proporcionam uma rigidez e protegem o olho de infecções (Costanzo, 2011).

Considerando que a ferramenta de estudo deste trabalho trata-se de imagens do fundo do olho, a camada que representa esta estrutura interna, é a retina.

2.2 Retina

A retina é definida por Costanzo (2011) como a camada nervosa do olho que possui uma complexa trama celular responsável pela recepção, transdução e processamento inicial dos estímulos visuais. Segundo Müller & Rudolph (1968), a retina reflete o laranja-avermelhado de um feixe luminoso emitido através da pupila, em um exame de fundoscopia.

Conforme Ramos (2006), a retina é uma membrana que preenche toda a parede interna do olho, com exceção do ponto cego (nervo ótico), contendo fotorreceptores que transformam a luz em impulsos elétricos, para que o cérebro possa interpretar as imagens. O nervo óptico transporta os impulsos elétricos captados pelos fotorreceptores da retina para o cérebro, o qual realiza a devida interpretação. Durante o exame de fundoscopia há a emissão de um feixe luminoso projetado no ponto cego do olho, o qual exibe uma região circular de alta intensidade. A mácula é o ponto central da retina, o qual é projetado o eixo óptico. Na depressão da mácula, denominada de fóvea, é o local em que o eixo visual é projetado (Costanzo, 2011).

As estruturas internas que podem ser observadas em imagens da retina, de pacientes sem anormalidades, são o nervo óptico, mácula, fóvea, veias e artérias, como ilustrado na Figura 2.2.

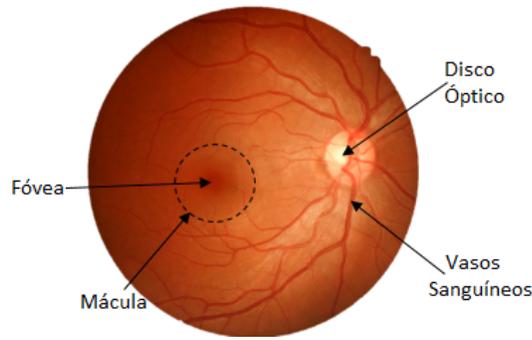


Figura 2: Retina humana.
Fonte: Adaptado de (Kälviäinen & Uusitalo, 2007).

2.3 Doenças Oculares

A visão nos dá acesso à maioria das informações sobre o mundo a nossa volta (Conselho Brasileiro de Oftalmologia, 2014). Porém, existem lesões e doenças à retina que deixam sequelas, e podem comprometer o sistema visual de forma temporária ou definitiva.

As doenças oculares mais comuns, como o glaucoma, a catarata, a degeneração macular e a conjuntivite, podem comprometer a visão de forma permanente. Conforme o Conselho Brasileiro de Oftalmologia (2014), as definições das doenças oculares são descritas a seguir:

- Glaucoma: É uma doença ocular que provoca lesão no nervo óptico e campo visual.
- Catarata: É definida como qualquer opacificação do cristalino que atrapalhe na passagem de luz através do olho.
- Degeneração Macular: É descrita como a degradação da área macular, geralmente acomete pacientes com mais de 60 anos.
- Conjuntivite: É a inflamação da conjuntiva (parte branca do olho).

Na Tabela 3 é exposto um resumo sobre o principal efeito causado por cada doença ocular. A ilustração das mesmas pode ser observadas na Figura 3.

Além das doenças oculares comuns, a perda visual dos pacientes também pode ser dada pelo descontrole de doenças sistêmicas. No caso de pacientes diabéticos e hipertensos, não controlados, é desencadeada uma doença secundária, a retinopatia, ou lesão na retina.

Tabela 3: Resumo dos efeitos causados pelas doenças oculares.

Doenças Oculares	Efeitos causados
Glaucoma	Lesão no nervo óptico
Catarata	Opacificação do cristalino
Degeneração Macular	Degradação da mácula
Conjuntivite	Inflamação da conjuntiva



(a) Glaucoma



(b) Catarata



(c) Degeneração Macular



(d) Conjuntivite

Figura 3: Doenças oculares.

Fonte: (Conselho Brasileiro de Oftalmologia, 2013).

2.4 Retinopatia Diabética

A falta de controle da Diabetes *Mellitus* (DM) pode causar muitos danos e seus efeitos podem ser observados claramente na camada interna do olho, em que possui vasos sanguíneos e nervos, os quais são os principais alvos (Sociedade Brasileira do Diabetes, 2014).

Conforme a Diretriz lançada pelo Conselho Brasileiro de Oftalmologia, no período de 2014 - 2015, a Retinopatia Diabética (RD) aparece após 20 anos do início da DM, acometendo aproximadamente 90% dos pacientes. Os sintomas que podem ser causados pela retinopatia são:

- Visão embaçada;
- Perda súbita de visão;

- Diminuição de visão noturna;
- Visão dupla;
- Mudanças repentinas na qualidade da visão;
- Enxergar pontos negros.

A retinopatia diabética (RD) é uma lesão na retina causada pelas complicações da DM. Pelo fato do organismo não conseguir processar a glicose de maneira adequada, ocorre o acúmulo de açúcares no sangue que irritam os vasos sanguíneos, rompendo-os, liberando fluido sanguíneo para área retiniana (Sopharak, 2008). A RD pode ser classificada em duas formas: não proliferativa e proliferativa. Em ambos os casos, a retinopatia pode ocasionar a perda parcial ou total da visão se não diagnosticada e tratada em sua fase inicial.

A retinopatia não proliferativa gera a fragilidade dos vasos sanguíneos, em que ocasionam o vazamento de sangue na área retiniana. Segundo Kälviäinen & Uusitalo (2007) a primeira anormalidade que é perceptível é a microaneurisma, com a evolução desta patologia podem ocorrer hemorragias e regiões exsudativas. As microaneurismas são pequenos pontos vermelhos resultantes de dilatações nos ramos terminais das veias e artérias, que rompem-se liberando fluido sanguíneo para a retina. A Figura 2.4 ilustra o surgimento e rompimento das microaneurismas.

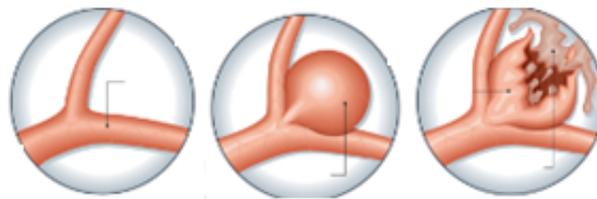


Figura 4: Início da retinopatia diabética, microaneurismas.
Fonte: Autoria própria.

Com a evolução das microaneurismas originam-se as hemorragias, no momento em que ocorre o rompimento das veias e artérias pelas microaneurismas, há o acúmulo de sangue na retina. Este sangue depositado são caracterizados em imagens da retina como regiões vermelhas, sendo assim as hemorragias. Os exsudatos são regiões de tonalidade amarelada

de alta intensidade, formadas pelo acúmulo de fluido sanguíneo na área retiniana juntamente com o depósito de açúcares (Kälviäinen & Uusitalo, 2007).

A Figura 5 é uma imagem fundoscópica, de um paciente, disponibilizada pelo banco de dados da *Diaretdb1* (Kälviäinen & Uusitalo, 2007). A imagem do fundo do olho deste paciente apresenta as três patologias da retinopatia diabética, caracterizando um quadro evolutivo da doença.

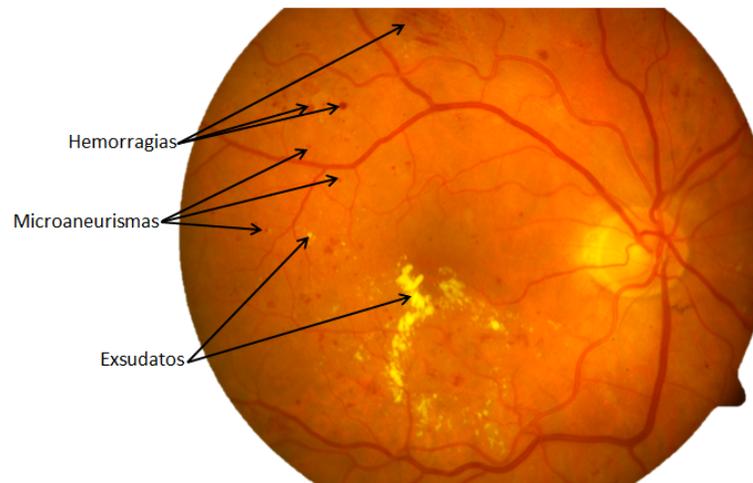


Figura 5: Evolução da retinopatia diabética não proliferativa.
Fonte: Adaptado de (Kälviäinen & Uusitalo, 2007).

Por outro lado, a retinopatia proliferativa, ilustrada na Figura 6, acontece quando os vasos sanguíneos anormais, denominados de neovasos, crescem na própria retina, podendo encharcar o olho de sangue com grandes chances de deslocamento de retina.

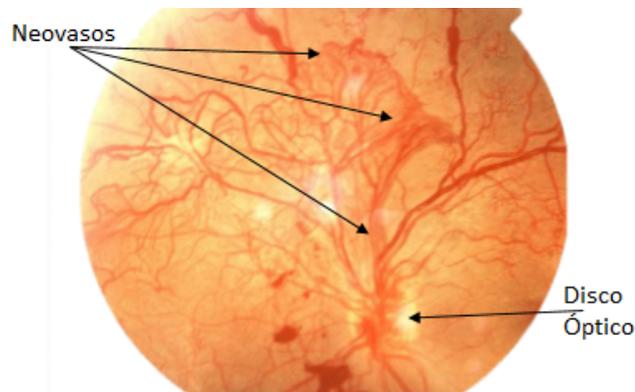


Figura 6: Retinopatia diabética proliferativa.
Fonte: Autoria própria.

3 Processamento Digital de Imagens

Neste capítulo são descritas algumas técnicas de processamento digital de imagens, tais como, filtragem espacial, morfologia matemática e a transformada de Hough, utilizadas para desenvolvimento do trabalho.

As transformações de imagens possuem uma diversidade de aplicações, por exemplo, a extração de características, evidência de estruturas e suavização de imagens (Pedrini & Schwartz, 2008). As técnicas de processamento de imagens tem a função de melhorar a qualidade da imagem, realizando transformações em seu sistema espacial ou espectral.

3.1 Imagem

A imagem é uma matriz que pode ser definida como uma função de intensidade luminosa $f(x, y)$, cujo valor nas coordenadas espaciais (x, y) fornece a intensidade ou o brilho da imagem daquele ponto (Pedrini & Schwartz, 2008). Por convenção, a origem das coordenadas espaciais localizam-se no canto esquerdo superior da imagem, seguindo da esquerda para a direita e de cima para baixo.

3.2 Filtragem no Domínio Espacial

O domínio espacial refere-se ao próprio plano da imagem, sendo que as abordagens nessa categoria são baseadas na manipulação direta dos *pixels*. O processo de filtragem neste domínio, normalmente é realizado por meio de matrizes que são representadas por máscaras, como é mostrado na Figura 7, que percorrem toda a extensão da imagem, da esquerda para a direita, de cima para baixo.

O processo de transformação em imagens, no domínio espacial, é decorrente de um sinal de entrada o qual passará por transformações, resultando assim em um novo sinal, um sinal de saída. A expressão matemática que define este processo é dada a seguir.

$$g(x, y) = Tf(x, y) \tag{1}$$

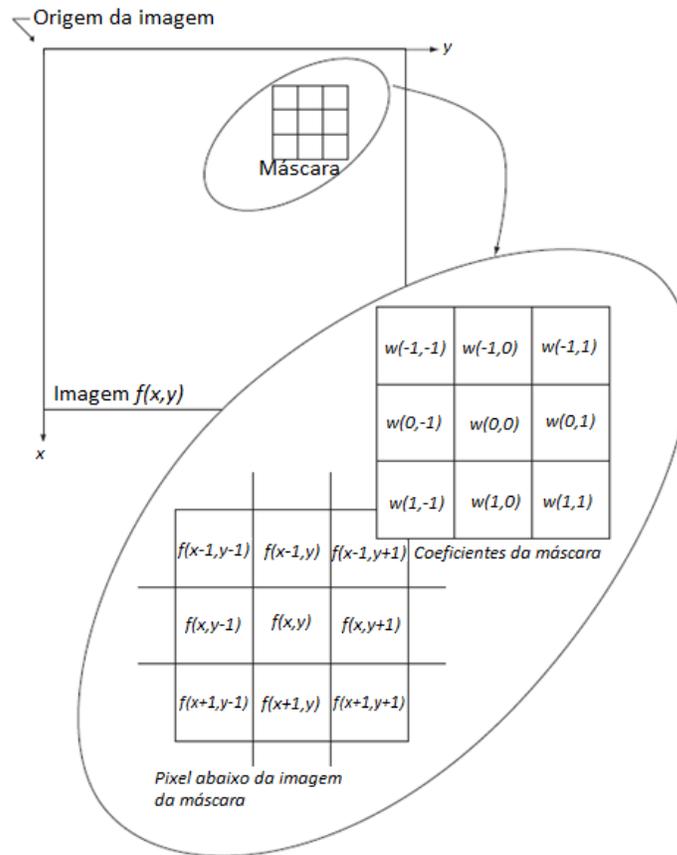


Figura 7: Vizinhança 3×3 ao redor do ponto (x, y) em uma imagem no domínio espacial.
 Fonte: (Gonzalez & Woods, 2010).

Na qual $f(x, y)$ é a imagem de entrada, $g(x, y)$ é a imagem de saída, e T é um operador em f que realiza transformações em imagens (Gonzalez & Woods, 2010).

Como exemplo de transformação em imagens, pode ser citado o filtro da média. Este filtro percorre toda a imagem, realizando nela modificações que suavizam seus contornos.

3.2.1 Filtro Espacial de Suavização

Os filtros de suavização são operadores de transformações implementados com a finalidade de realizar o borramento e redução de ruídos em imagens. Segundo Gonzalez & Woods (2010), o efeito de borramento são utilizados em etapas de pré-processamento digital, assim como a remoção de pequenos detalhes da imagem antes da extração de objetos grandes e conexão de pequenas descontinuidades. Este tipo de filtro é denominado de filtro da média ou filtro passa-baixa (Gonzalez & Woods, 2010).

Conforme Gonzalez & Woods (2010), a ideia por trás do filtro de suavização é substituir os valores de cada *pixel* de uma imagem pela média dos níveis de intensidade da vizinhança definida pela máscara. O efeito causado por este processo é a redução de transições abruptas nas intensidades dos *pixels*, que correspondem por ruídos aleatórios e bordas.

Os filtros geralmente percorrem a imagem por blocos, um exemplo deles é o filtro da média 3×3 com origem no centro, dado por

$$Máscara_{Media(3x3)} = \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (2)$$

3.3 Morfologia Matemática

A morfologia matemática utiliza a teoria de conjuntos para representar a forma dos objetos em uma imagem (Pedrini & Schwartz, 2008). Por convenção, em imagens binárias os objetos encontrados em uma imagem são representados por *pixels* brancos (valor 1), enquanto o fundo será formado por *pixels* pretos (valor 0).

O processamento morfológico de imagens é projetado para formular operadores matemáticos que utilizam conjuntos estruturantes. A estrutura desses conjuntos são bastante flexíveis, sua forma e tamanho são ajustados conforme a necessidade do problema. As formas mais comuns utilizadas na literatura são em forma de cruz, quadrado e diamante, conforme mostrado na Figura 8. A coordenada central, ou coordenada de referência dos conjuntos estruturantes, são representados por ponto vermelho.

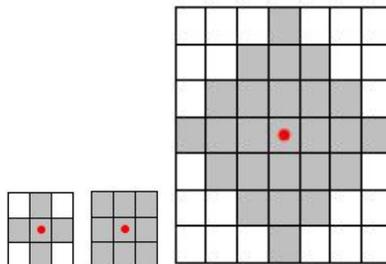


Figura 8: Conjuntos estruturantes.
Fonte: Adaptado de (Gonzalez & Woods, 2010).

Segundo Gonzalez & Woods (2010), quando se trabalha com imagens, as formas dos

conjuntos estruturantes devem ser arranjos matriciais retangulares. Os autores relatam que ao implementar filtros com conjuntos estruturantes retangulares o número de elementos de fundo representado pelos quadrados de cor branca, são minimizados.

Ao realizar operações morfológicas em imagens, pode-se construir seu próprio conjunto estruturante ou utilizar um que a biblioteca de processamento de imagens disponibiliza. Na Figura 9, é mostrado como construir uma matriz de forma circular com dimensões de 9×9 , que representa um modelo de conjunto estruturante utilizado em operações morfológicas.

```
Circular=[ [0, 0, 0, 1, 1, 1, 0, 0, 0],
           [0, 1, 1, 1, 1, 1, 1, 1, 0],
           [0, 1, 1, 1, 1, 1, 1, 1, 0],
           [1, 1, 1, 1, 1, 1, 1, 1, 1],
           [1, 1, 1, 1, 1, 1, 1, 1, 1],
           [1, 1, 1, 1, 1, 1, 1, 1, 1],
           [0, 1, 1, 1, 1, 1, 1, 1, 0],
           [0, 1, 1, 1, 1, 1, 1, 1, 0],
           [0, 0, 0, 1, 1, 1, 0, 0, 0] ]
```

Figura 9: Representação de conjuntos estruturantes na forma de uma matriz.
Fonte: Autoria própria.

Utilizando a lógica binária, os elementos compostos pelo numeral 1 são considerados com nível lógico alto (branco), e os elementos compostos pelo numeral 0 são considerados em nível lógico baixo (preto).

3.3.1 Erosão e Dilatação

Existem duas transformações morfológicas primordiais em processamento de imagens, que são a erosão e a dilatação, ambas utilizam conjuntos estruturantes para realizar suas operações matemáticas. (Gonzalez & Woods, 2010).

A operação de erosão, denotada por $A \ominus B$, é uma transformação morfológica entre dois conjuntos usando interseção vetorial, expressa pela Equação 3. (Facon, 2011).

$$A \ominus B = \{x|(B)_x \subseteq A\} \quad (3)$$

A erosão de um conjunto A por um conjunto estruturante B resulta em um conjunto de pontos x tais que B transladado de x está contido em A , ou seja, quando o conjunto estruturante B percorre todo o conjunto A , ele subtrai do conjunto A pontos que não estejam em intersecção com o conjunto B . Este tipo de operação é utilizada para separar objetos em imagens.

Na Figura 10, é apresentado um exemplo da transformação do conjunto A por um conjunto estruturante B , em uma operação de erosão. A letra (b) é o conjunto estruturante responsável por realizar a operação morfológica de erosão, sob um conjunto apresentado na letra (a). O conjunto (b) percorre todo conjunto (a) subtraindo dele pontos que não estejam em intersecção, este fato pode ser observado na letra (c). Ao realizar uma operação de erosão entre os conjuntos (a) e (b) ocorre a separação de elementos do conjunto (a), conforme a imagem da letra (d).

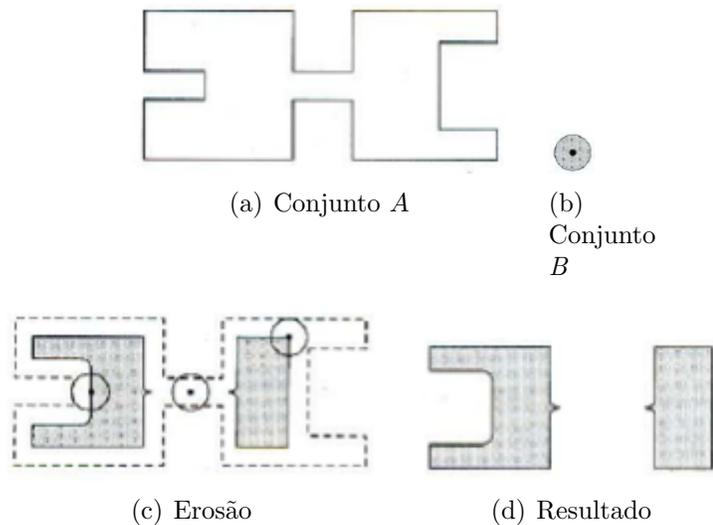


Figura 10: Operação de erosão do conjunto A pelo conjunto estruturante circular B .
 Fonte: (Gonzalez & Woods, 2010).

Diferentemente da erosão, a operação de dilatação realiza a expansão do conjunto A . Na dilatação, denotada por $A \oplus B$ ocorre a combinação de dois conjuntos usando adição vetorial, esta técnica é usada para preenchimento de espaço (Facon, 2011). A dilatação de uma conjunto A por um conjunto estruturante B é então o conjunto de todos os pontos x deslocados para os quais à intersecção de B em A . Em outras palavras, a dilatação de A por B ocorre quando pelo menos um elemento do conjunto B está em intersecção com

o conjunto A , desta forma, os demais elementos de B são adicionados ao conjunto A . A expressão matemática que descreve esta técnica é mostrada na Equação 4.

$$A \oplus B = \{x | (B)_x \cap A \neq \emptyset\} \quad (4)$$

A Figura 11 ilustra um exemplo da transformação realizada durante uma operação de dilatação de um conjunto A por um conjunto estruturante B . A letra (b) é o conjunto estruturante responsável por realizar a operação de dilatação, sob um conjunto apresentado na letra (a). O elemento (b) percorre todo conjunto (a) adicionando a ele pontos que estejam com pelo menos um elemento do conjunto (b) em intersecção, este fato pode ser observado na letra (c). Ao realizar uma operação de dilatação entre os conjuntos (a) e (b) ocorre a adição de elementos no conjunto (a), conforme a imagem da letra (d).

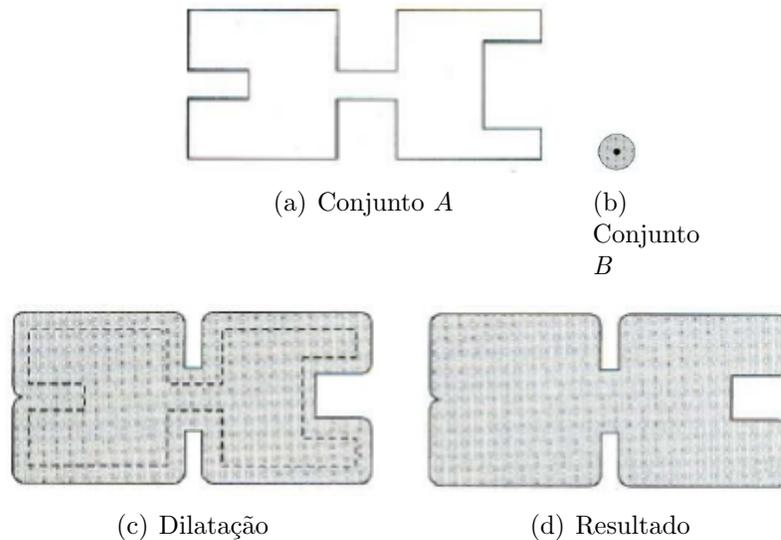


Figura 11: Operação de dilatação do conjunto A pelo conjunto estruturante circular B .

Fonte: (Gonzalez & Woods, 2010).

3.3.2 Abertura e Fechamento

Outras duas operações morfológicas em análise de imagens são a abertura e o fechamento (Pedrini & Schwartz, 2008). Segundo Gonzalez & Woods (2010), a abertura denotada por $A \circ B$ é uma operação morfológica que suaviza o contorno geométrico dos objetos contidos em uma imagem, consistindo basicamente em realizar uma operação de erosão de A por B

seguida de uma dilatação do resultado com B .

A Figura 12 ilustra uma operação morfológica de abertura. A letra (a) representa o conjunto original, o qual passará pelos processos de abertura. Utilizando um conjunto estruturante circular é realizada uma operação de erosão, o resultado deste processo pode ser observado na letra (b). Após a erosão é implementada uma operação de dilatação, utilizando o mesmo conjunto estruturante circular, sob o conjunto erodido, o resultado pode ser observado na letra (c).

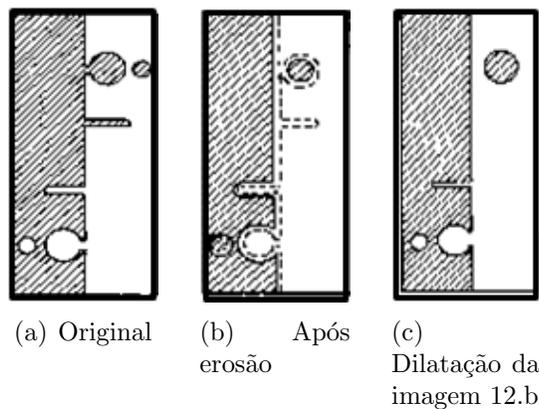


Figura 12: Representação de uma operação de abertura.
Fonte: (Gonzalez & Woods, 2010).

A forma matemática que descreve a operação de abertura de um conjunto A pelo conjunto estruturante B , denotada por $A \circ B$, é expressa pela Equação 5.

$$A \circ B = (A \ominus B) \oplus B \quad (5)$$

De forma contrária, no fechamento ocorre uma dilatação seguida de uma erosão do resultado com B . Esta técnica é usada para apagar elementos indesejáveis da imagem ou separar elementos. A forma matemática que descreve esta operação morfológica dada por

$$A \bullet B = (A \oplus B) \ominus B \quad (6)$$

Um exemplo de uma operação de fechamento é ilustrado na Figura 13. A letra (a) representa o conjunto original, o qual passará pelos processos de fechamento. Utilizando um conjunto estruturante circular é realizada uma operação de dilatação, o resultado deste

processo pode ser observado na letra (b). Após a dilatação é implementada uma operação de erosão, utilizando o mesmo conjunto estruturante circular, sob o conjunto dilatado, o resultado pode ser observado na letra (c).

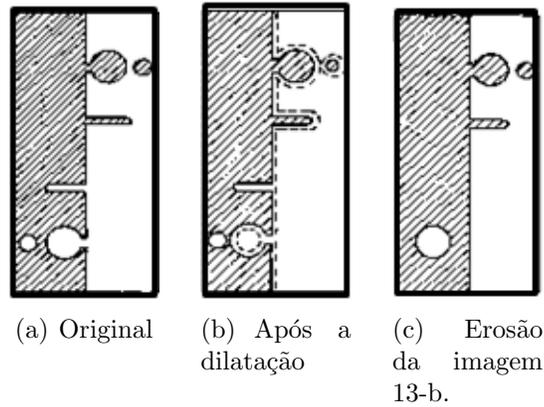


Figura 13: Representação de uma operação de fechamento.
 Fonte: (Gonzalez & Woods, 2010).

3.4 Transformada de Hough

Desenvolvida por Paul Hough (1962), a transformada refere-se ao reconhecimento de padrões complexos. A Transformada de Hough (TH) é um método padrão para detecção de formas que são facilmente parametrizadas em imagens digitalizadas, como linhas, círculos e elipses. Segundo Chavez *et al.* (2010), na imagem pode-se aplicar a TH tal que todos os pontos pertencentes a uma mesma curva sejam mapeados.

3.4.1 Transformada Circular de Hough

Considerando que neste trabalho a forma geométrica a ser encontrada pela transformada se trata de um círculo (disco óptico), foi estudada e implementada a transformada circular de Hough.

De modo intrínseco, esta transformada realiza inicialmente uma suavização das imagens através do filtro gaussiano. Matematicamente, a aplicação do filtro gaussiano é realizada da mesma forma que a convolução da imagem com uma função gaussiana, como um filtro passa baixa, ou como um filtro de média simples, conforme a Equação 7. (Jesus & Costa Jr, 2015).

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2 + y^2}{2\sigma^2}} \quad (7)$$

Em que $G(x, y)$ é o sinal de saída, x distância da origem no eixo horizontal, y distância da origem no eixo vertical e σ é o desvio padrão da distribuição gaussiana dos *pixels* que compõem a imagem. Segundo Gonzalez & Woods (2010) o filtro gaussiano possui transição suave de borramento conforme o afastamento da origem no eixo horizontal, por este não possuir transições abruptas, ele apresenta uma importante característica na prática, especialmente em situações (por exemplo, de imagens médicas) nas quais artefatos de qualquer natureza são inaceitáveis.

Após a suavização, a transformada de Hough utiliza o método do gradiente para obter informações de bordas em imagens, através do operador de Canny. O gradiente de uma imagem (∇f) é computado nas direções de x e y , linhas e colunas, como a

$$\nabla f = [(G_x/G_y)], \quad (8)$$

em que $G_x = \frac{\partial f}{\partial x}$, correspondendo pela derivada parcial da imagem com relação as linhas e $G_y = \frac{\partial f}{\partial y}$, que corresponde pela derivada parcial da imagem com relação as colunas. A direção (θ) do gradiente utilizada no operador de Canny é descrita pela Equação 9.

$$\theta = \tan^{-1}(G_x/G_y) \quad (9)$$

Em seguida, a transformada de Hough gera uma matriz acumuladora, que realiza o armazenamento das coordenadas dos *pixels* de borda, detectados pelo operador de Canny conforme Figura 14. O detector de bordas é fundamental para construir a matriz acumuladora de Hough, visto que, a matriz guarda a evidência de círculo para cada *pixel* de borda, e acrescenta a ele 16 *pixels* de raio nas direções de x e y (Hough, 1962).

Segundo Silva *et al.* (2013) o problema da detecção de circunferências com raio fixo consiste em determinar quais os pontos de uma imagem pertencem a uma mesma circunferência de raio r . Ou seja, tem-se um conjunto de coordenadas (x, y) e pretende-se encontrar valores possíveis para os parâmetros (x_c, y_c) , correspondentes aos pontos centrais de circunferências. Para isso, constrói-se um espaço de Hough, que para o caso específico, pode ser

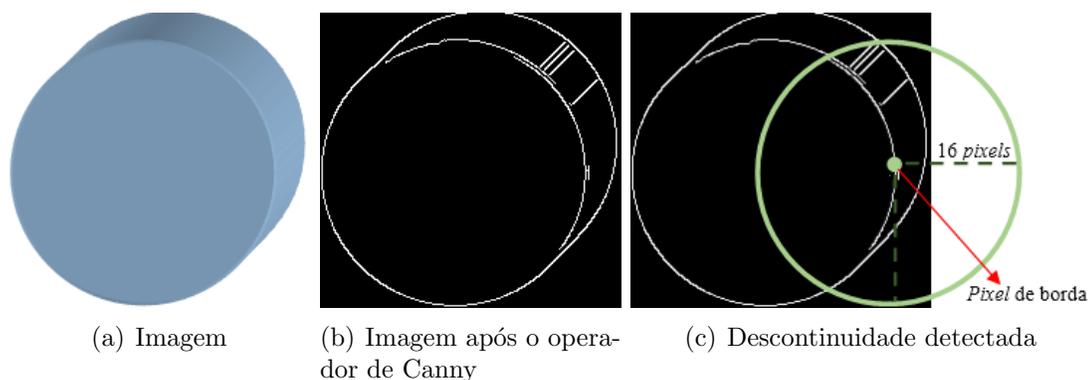


Figura 14: Representação de uma implementação da transformada de Hough.
 Fonte: Autoria própria.

visto como uma matriz, com a mesma dimensão da imagem digital, em que as colunas e linhas representam, respectivamente, os possíveis valores de x_c e y_c , como mostra a Figura 15.

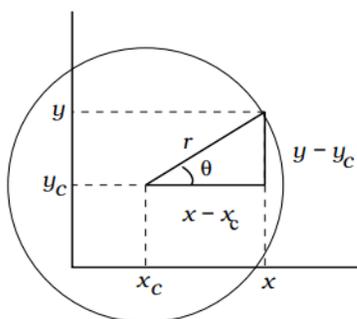
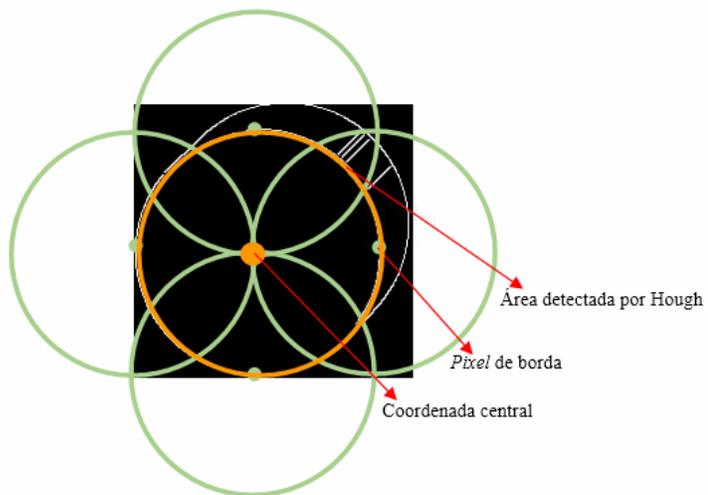
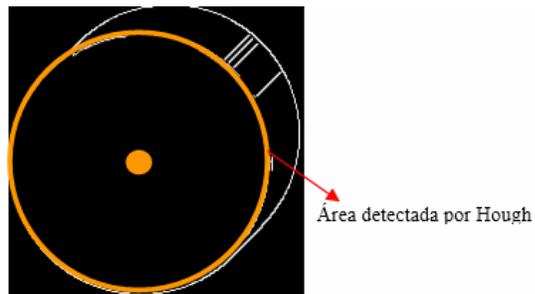


Figura 15: Representação do espaço de Hough.
 Fonte: (Silva *et al.* , 2013).

Cada célula da matriz de acumulação recebe, inicialmente, o valor zero, e para cada ponto (x, y) da imagem, incrementa-se no espaço de Hough, todas as células (x_c, y_c) representando centros de circunferências de raio r , que passam por (x, y) . Ao final, as células contendo os valores mais altos indicarão os centros "mais prováveis" de circunferências (Silva *et al.* , 2013), detectando assim, áreas circulares em imagens, conforme Figura 16.



(a) Pontos de acumulação



(b) Resultado

Figura 16: Acumulador de Hough.
 Fonte: Autoria própria.

4 Algoritmo Bioinspirado na Colônia Artificial de Abelhas

A inteligência de enxame tornou-se um interesse de estudo para muitos cientistas pesquisadores de áreas afins, nos últimos anos (Karaboga, 2005). Segundo Karaboga (2005), atualmente existem diversos algoritmos bioinspirados no comportamento natural, sendo alguns deles, a colônia de abelhas (*Bee Colony*), colônia de formigas (*Ant Colony*), otimização por enxame de partículas (*Particle Swarm Optimization*), aprendizado de peixes (*Fish Schooling*), cadeia de genes (*Gen Strings*) e a massa celular (*Cell Mass*).

Os algoritmos bioinspirados fazem uso do processo biológico e comportamento de seres vivos traduzidos por meio de operações e linguagem matemática, fazendo parte da classe de algoritmos meta heurísticos e estocásticos que trabalham com o objetivo de buscar soluções para problemas cujo espaço de busca possui dimensionalidade de grau elevado (Bagesteiro, 2017).

Conforme Karaboga (2005), dois conceitos são fundamentais quando se trata de colônias ou enxames, sendo eles a auto-organização e a divisão do trabalho. As propriedades citadas são suficientes para obter um comportamento inteligente, como resolução de sistemas que se auto-organizam e se adaptam ao ambiente dado:

- Auto-Organização: Os processos auto-organizados são processos coletivos, em que unidades que fazem parte deste coletivo competem, com chances de sucesso semelhantes, por recursos limitados. Chances semelhantes implicam na inexistência de hierarquias ou de elementos privilegiados (Costa *et al.* , 1999).
- Divisão do Trabalho: Execução simultânea de tarefas em uma colônia ou exame, que são realizadas por indivíduos especializados.

Desenvolvido por Karaboga em 2005, o algoritmo *Artificial Bee Colony* (ABC) realiza uma otimização estocástica simples, sendo robusto e baseado na população de enxames. Aplicado como ferramenta de otimização, o algoritmo ABC simula o comportamento das abelhas na busca por alimentos, este fenômeno se repete até que seja obtida uma solução

ótima ou atingido o critério de parada (Karaboga, 2005). Segundo Nakamura (2017), existem três tipos básicos de abelhas: empregadas, espectadoras e escoteiras.

Na Figura 4 é ilustrado o fluxograma do algoritmo ABC que resultam no processo de busca pelas fontes de alimento.



Figura 17: Fluxograma do algoritmo ABC.
Fonte: Autoria própria.

A implementação do algoritmo ABC é descrito em passos, como mostra a seguir.

1º Passo: Definir alguns parâmetros de controle, como, o tamanho do população de abelhas, contador máximo de falhas, ciclo máximo de iterações e a quantidade de níveis cinza da imagem.

2º Passo: Realizar a leitura do sinal de entrada, que neste caso, as imagens.

3º Passo: Realizar o cálculo do histograma das imagens.

4º Passo: Definir o parâmetro que irá segmentar as imagens. Por exemplo, a entropia máxima de Kapur.

5º Passo: Definir a função objetivo.

6º Passo: Inicializar a colônia de abelhas.

7º Passo: Calcular a função objetivo para cada fonte de alimento.

8º Passo: Calcular a vizinhança da fonte inicial, distanciando-se em direção de uma fonte aleatória.

9º Passo: Verificar se o valor retornado no passo anterior é melhor do que o valor da fonte inicial. Caso seja, pinte de branco os *pixels* referente a fonte inicial. Caso contrário, incremente o contador de falhas.

10º Passo: Calcular a aptidão de cada fonte de alimento.

11º Passo: Ordenar os valores de aptidão de cada fonte para classificar em ordem crescente a melhor, ou aquela fonte com maior probabilidade de conter a patologia.

12º Passo: Verificar se os critérios de parada foram atingidos.

13º Passo: Caso resposta do passo anterior for sim, repita desde o 1º passo.

Na inicialização é gerada a colônia de abelhas, o qual são responsáveis por buscarem as primeiras fontes de alimento. No primeiro bloco, referente a fase das abelhas empregadas, são realizadas buscas por melhores fontes em que é executada uma comunicação com as abelhas espectadoras através de uma dança, a qual contém informações sobre a direção, distância e qualidade das fontes de alimento. No bloco das abelhas espectadoras, a comunicação recebida pelas abelhas empregadas e a aptidão daquela fonte impulsionam o deslocamento das espectadoras a coletarem mel naquele local. No último bloco, as abelhas escoteiras realizam a verificação das fontes exploradas pelas abelhas expectadoras, para certificar se aquela fonte se esgotou. Este processo se repete até atingir os critérios de parada.

Segundo Karaboga (2005), o modelo de forragem de abelhas, isto é, o processo em que as abelhas buscam as fontes de alimentos, levam ao surgimento da inteligência coletiva de enxames de abelhas consistindo em três componentes essenciais: fontes de alimento, abelhas empregadas e abelhas escoteiras. O modelo define dois modos principais do comportamento: o recrutamento para uma fonte de alimento e o abandono de uma fonte.

- Fontes de Alimento: O valor de uma fonte de alimento depende de muitos fatores, como

sua proximidade com o ninho e sua riqueza.

- Abelhas Empregadas: Estão relacionadas a uma determinada fonte de alimento que atualmente estão sendo explorada. Elas trazem consigo informações sobre a fonte que exploram, a distância e direção do ninho, a rentabilidade da fonte, compartilhando essas informações.
- Abelhas Escoteiras: Realizam pesquisas do ambiente em torno do ninho, verificando se as fontes exploradas foram esgotadas, a fim de buscar novas fontes de alimentos.

Disponibilizado por Karaboga (2005), o pseudocódigo do algoritmo ABC é descrito na Figura 18, o qual é composto por 11 regras que caracterizam o funcionamento do algoritmo artificial de abelhas.

1. FASE DE INICIALIZAÇÃO
2. **REPETIR**
3. Fase das abelhas empregadas
4. Retorne a melhor fonte
5. Fase das abelhas espectadoras
6. Calcule a aptidão das fontes
7. Fase das abelhas escoteiras
8. Verifique se as fontes esgotaram
9. Memorize a melhor solução alcançada até agora
10. Critério de parada (melhor solução ou ciclo máximo de interações)
11. FIM

Figura 18: Regras para a implementação do algoritmo da colônia artificial de abelhas.
Fonte: Autoria própria.

4.1 Abelhas Empregadas

As abelhas empregadas são responsáveis por buscar as primeiras fontes de alimento no ambiente a ser explorado. Todos os vetores da população de fontes alimentares (x_i) são

inicializados ($i= 1, \dots, SN$), em que SN é o tamanho da população artificial de abelhas. Como cada fonte de alimento (x_i) é um vetor de solução para o problema de otimização, cada vetor contém variáveis (n), ($j= 1, \dots, SN$) e ($i= 1, \dots, n$), que devem ser otimizados para minimizar a função objetivo.

No algoritmo de Karaboga (2005), inicialmente as abelhas são dispostas no campo da imagem através de uma geração aleatória, que retorna um número aleatório inteiro (N) em um intervalo de 1 a 256 níveis, quando a imagem se encontra em tons de cinza, para que cada fonte de alimento (i) seja correspondida por uma abelha empregada da colônia. A etapa de inicialização da colônia de abelhas é ilustrada na Figura 19.

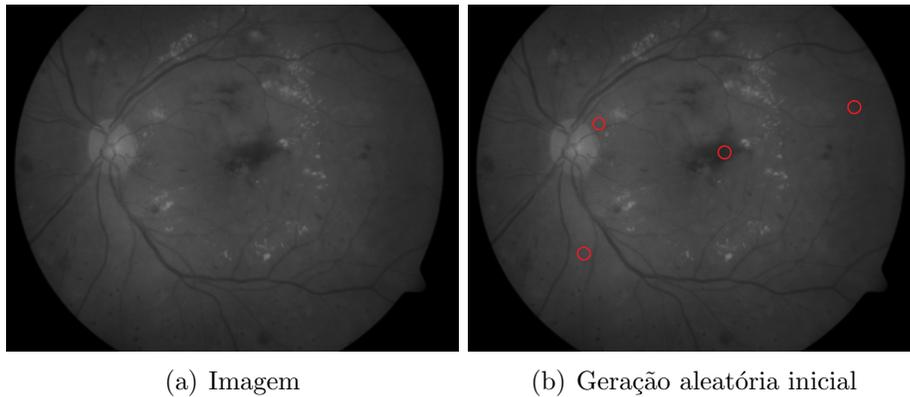


Figura 19: Inicialização da colônia de abelhas.
Fonte: Autoria própria.

As abelhas empregadas exploram a vizinhança das fontes de alimento inicial (x_{ij}), distanciam-se em direção à uma fonte aleatória (x_{kj}). A fonte aleatória k retorna um número aleatório inteiro em um intervalo de 1 até o número da população de abelhas. Então, supondo que o tamanho da colônia inicial seja igual a 10, o valor de k retornará um número aleatório entre 1 e 10.

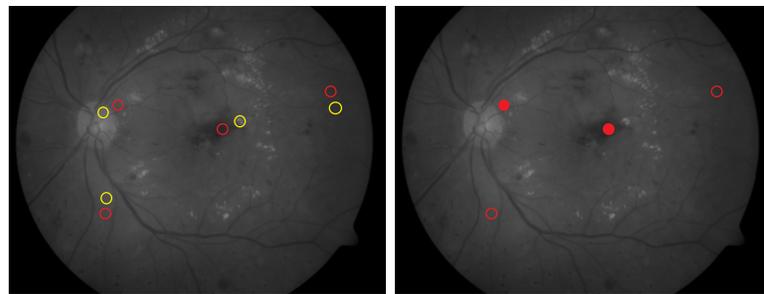
A verificação dos *pixels* vizinhos (v_{ij}) da fonte inicial (x_{ij}) é realizada conforme Equação 10.

$$v_{ij} = x_{ij} + \phi_{ij}(x_{kj} - x_{ij}) \quad (10)$$

O parâmetro (ϕ_{ij}) é uma distribuição uniforme, ou seja, trata-se de uma posição a qual a amostra é pintada uma região de *pixels* de mesma intensidade luminosa.

A Figura 20 ilustra o comportamento de exploração da vizinhança da fonte inicial, executada pela abelha empregada. Os círculos vermelhos indicam as fontes iniciais e os círculos amarelos, as fontes aleatórias. Caso a fonte inicial obtenha uma vizinhança com uma boa qualidade, seus *pixels* serão pintados, indicando assim, que esta região possui grande probabilidade de conter exsudatos.

A letra (a) mostra como ocorre a verificação da qualidade da vizinhança ao entorno da fonte inicial. Na letra (b) é representada a forma que o algoritmo ABC realiza a binarização, ou segmentação das imagens, conforme a qualidade de cada fonte de alimento.



(a) Exploração dos *pixels* vizinhos (b) Provável região de patologia

Figura 20: Exploração dos *pixels* vizinhos à fonte de alimento inicial.
Fonte: Autoria própria.

Se o valor de (v_{ij}) for maior que 1, a fonte é atualizada, senão, será mantido o valor da fonte inicial (x_{ij}) , isto é, se a intensidade luminosa dos *pixels* da nova região (v_{ij}) for maior que a anterior (x_{ij}) , a fonte se atualiza. O melhor valor obtido pelas fontes de alimento é memorizado, uma fonte é dita melhor que a anterior a partir da função objetivo (fit_i) expressa pela Equação 11.

$$fit_i = \begin{cases} \frac{1}{1+f_i}, & \text{se } f_i \geq \text{limiar} \\ 1 + |f_i|, & \text{se } f_i < \text{limiar} \end{cases} \quad (11)$$

A função objetivo é definida pela entropia de Kapur *et al.* (1985), o qual f_i é o vetor que mantém os valores da função objetivo associados as fontes de alimento entre o intervalo de $[0, 1]$ em imagens binárias. Se o valor do vetor correspondente a fonte de alimento (i) for maior ou igual ao limiar estabelecido, seu valor será forçado a permanecer abaixo de 0 e sua fonte recebe nível lógico (0) . Se o valor do vetor f_i for menor que o limiar, a fonte permanece

com valores acima de 1, recebendo nível lógico (1) e tendo mais probabilidade de ser uma fonte melhor.

A entropia de Kapur *et al.* (1985) consiste em calcular a probabilidade da ocorrência dos níveis de cinza das imagens, em que retorna um vetor de acumulação (a), definindo então o limiar máximo que irá segmentar as imagens.

Na Figura 21 é mostrado um exemplo de como determinar o limiar ($H0$) para segmentar imagens, sendo definido a partir do valor de probabilidade dos *pixels*. Se o valor da probabilidade for maior que zero, ($H0$) retornará o valor da razão entre a probabilidade dos *pixels* e a função logarítmica referente ao agrupamento de tons de cinza.

```
def = KapurEntropy (threshold):
    H0 = 0
    p = prob(0)
    a == acc[threshold - 1]
    if = p > 0:
        H0 -= p/a*math.log(p/a)
```

Figura 21: Representação de uma implementação da entropia de Kapur.
Fonte: Autoria própria.

A implementação da entropia de Kapur é realizada com base em dois parâmetros: p , a , que correspondem a probabilidade da ocorrência de níveis cinza, e agrupamentos dos tons de cinza, respectivamente. Caso o valor da probabilidade dos tons de cinza for maior que zero, é calculado um valor de limiar, responsável por segmentar as imagens digitais.

4.2 Abelhas Espectadoras

A troca de informações entre as abelhas é a ocorrência mais importante na formação do conhecimento coletivo (Karaboga, 2005). As abelhas empregadas trocam informações por meio de uma espécie de dança ao entorno da fonte de alimento. A aptidão das fontes são determinadas pela razão do vetor (f_i) sobre soma das funções objetivo ($\sum fit_i$) de cada fonte de alimento, descrita pela Equação 12.

$$Ap = \frac{f_i}{\sum fit_i} \quad (12)$$

A caracterização da dança na programação, corresponde pela localização do ponto de interseção das amostras com a aptidão de cada fonte. Os pontos de interseção são distribuídos uniformemente em uma lista de aptidões, que mantém a ordem classificatória, isto é, se a amostra gerada conter algum ponto de interseção com os valores de aptidão, a amostra permanecerá mais à esquerda da lista de classificação, sendo um grande candidato à ser escolhido.

4.3 Abelhas Escoteiras

As abelhas escoteiras são responsáveis por verificar se as fontes de alimento estão esgotadas. Uma fonte é dita esgotada quando o número máximo de tentativas de melhoria (atualização) da fonte é atingido. Nesta etapa é imposta uma condição de parada, que verifica se o número de falhas de determinada fonte de alimento (i) é igual ao contador máximo de falhas.

Se a fonte esgotar as abelhas empregadas são dispostas aleatoriamente novamente no campo da imagem de forma que se busquem novas fontes. O vetor (f_i) armazena o novo valor da função objetivo, incrementando o contador de falhas. O algoritmo se repete enquanto não atingido o número de interações, ciclo máximo de trabalho ou número máximo de falhas.

5 Metodologia

Neste capítulo, serão descritos os materiais e métodos utilizados para implementação do algoritmo baseado na colônia artificial de abelhas aplicado na identificação dos exsudatos, e as técnicas de processamento de imagens utilizadas para a detecção das microaneurismas. Os algoritmos desenvolvidos foram implementados em linguagem de programação *Python*, utilizando a biblioteca de processamento de imagens, a *OpenCV*.

5.1 Banco de Dados

Para o desenvolvimento do algoritmo proposto neste trabalho foi realizada a aquisição das imagens do banco de dados da *Diaretdb1*, que contém imagens do fundo do olho de 89 pacientes com e sem retinopatia diabética (Kälviäinen & Uusitalo, 2007). Segundo os autores do banco de dados, dos 89 pacientes, 84 foram diagnosticados com alguma patologia e apenas 5 são consideráveis pessoas saudáveis. Para cada paciente foram analisadas pelos médicos três patologias, então, o banco ao total contém 252 imagens de pacientes com alguma patologia e apresentando apenas 15 imagens de pacientes saudáveis.

As imagens coletadas são coloridas no espaço de cor RGB (*Red-Vermelho*, *Green-Verde* e *Blue-Azul*), possuindo dimensões de 1500×1152 *pixels*, salvas em formato *Portable Network Graphics* (PNG). As patologias diagnosticadas neste banco são as microaneurismas, hemorragias e exsudatos conforme Figura 22.

Dentre os dois tipos de retinopatia diabética, as imagens do banco de dados são caracterizadas por retinopatia não proliferativa, pois não há indícios de surgimento de neovasos em nenhuma imagem (Kälviäinen & Uusitalo, 2007). Para avaliar o algoritmo foram utilizadas todas as imagens do banco de dados, que são compostas pelos diagnósticos de duas patologias, exsudatos e microaneurismas.

5.2 Detecção dos exsudatos

Para detectar a retinopatia diabética, a primeira patologia a ser identificada será os exsudatos, devido o mesmo apresentar *pixels* com intensidade elevada o qual se destaca com relação ao fundo das imagens, facilitando sua identificação.

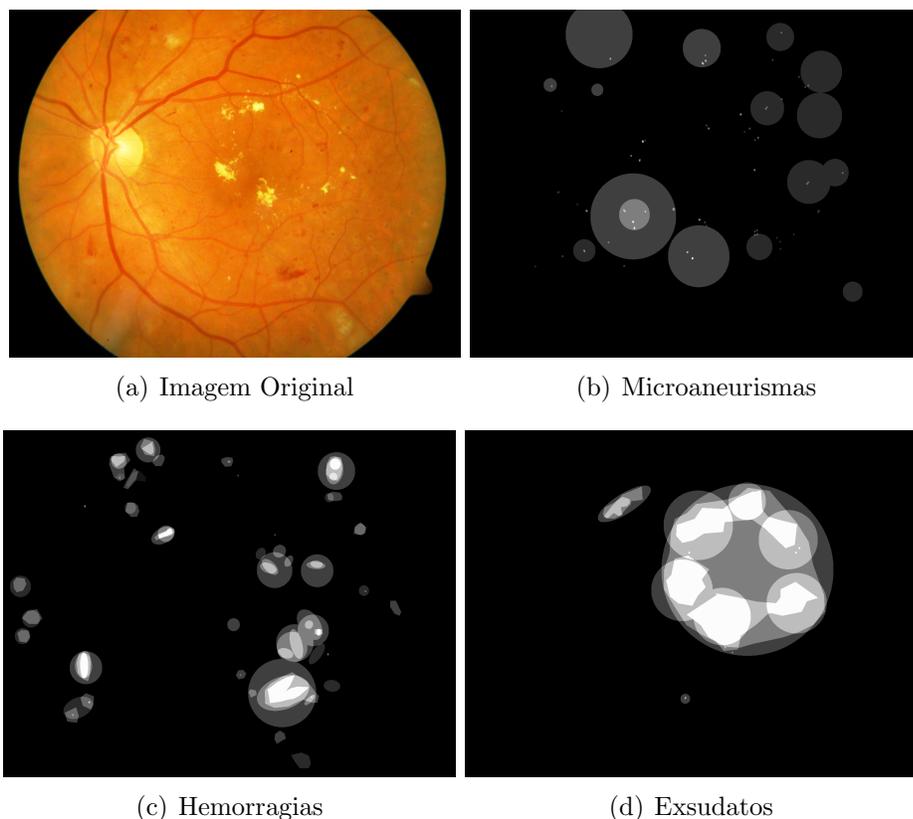


Figura 22: Diagnósticos referentes a imagem 015 do banco de dados da *Diaretdb1*.
 Fonte: (Kälviäinen & Uusitalo, 2007).

5.2.1 Pré-processamento

O pré-processamento inicia com a localização do disco óptico, pelo fato dele apresentar características de manchas amareladas com brilho intenso semelhantes aos exsudatos, podendo assim, confundir o algoritmo de detecção. Para mostrar como o algoritmo proposto se comporta, foram escolhidas quatro imagens do banco de dados, conforme Figura 23.

Após a aquisição das imagens, o filtro espacial linear de suavização, ou filtro da média, foi implementado com elemento estruturante quadrado 11×11 . O objetivo da execução deste filtro na imagem era aplicar um leve borramento sobre a mesma, removendo pequenos ruídos.

Em seguida foram separados os canais vermelho, verde e azul (R, G, B) das imagens coloridas. Com a extração do canal verde, as imagens resultantes apresentaram uma coloração em tons de cinza. Este canal foi escolhido baseando-se em testes realizados, uma vez que

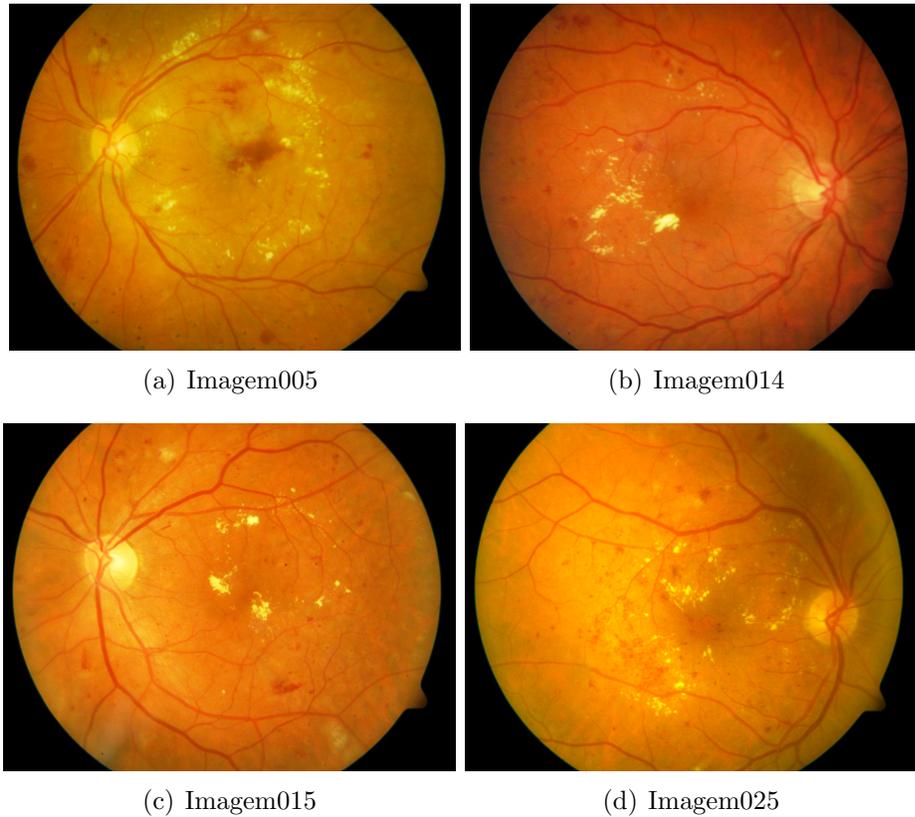


Figura 23: Imagens originais do banco de dados.
Fonte: Kälviäinen & Uusitalo (2007).

nessas imagens os exsudatos e o disco óptico ficaram mais evidentes.

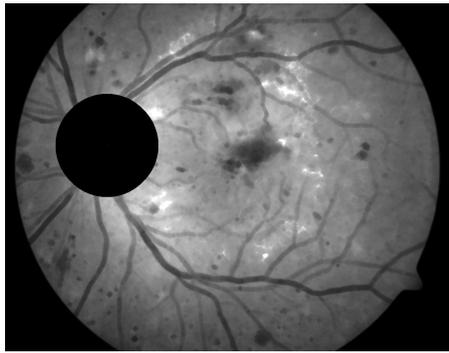
Logo após, uma operação de fechamento foi implementada utilizando parâmetros testados empiricamente. Para a operação de dilatação foi determinado o elemento estruturante cruz 15×15 e para erosão o elemento cruz 3×3 , em ambos foram executadas 20 interações.

O próximo passo foi a implementação da transformada circular de Hough, implementada utilizando a função da biblioteca *OpenCV*. Os valores dos parâmetros da transformada testados empiricamente são, 1300 para determinar a distância mínima entre a coordenada central da circunferência até o ponto de intersecção, 12 para o limite inferior e 20 para o limite superior utilizado no detector de borda *Canny*, 50 para o raio mínimo e 120 de raio máximo da circunferência, como mostra a Tabela 4.

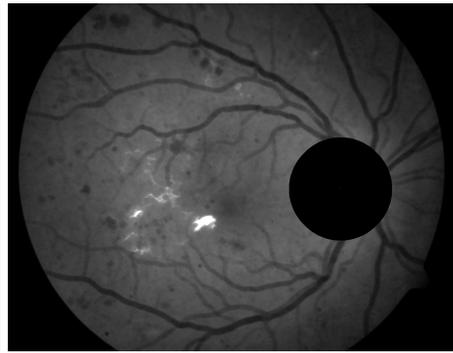
O resultado do conjunto de técnicas de processamento digital de imagens pode ser observado de acordo com a Figura 24. As imagens resultantes encontra-se em escala de cinza pelo fato do processamento ser feito com apenas um canal de cor, o canal verde.

Tabela 4: Parâmetros utilizados para implementação da TH em imagens.

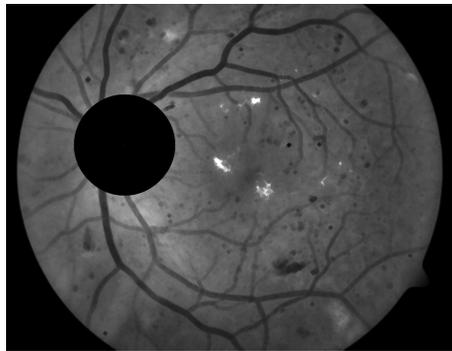
Imagem de entrada	Método de detecção	Distância mínima entre a coord. central	Limite inferior Canny	Limite superior Canny	Raio mínimo	Raio máximo
Erosion	Gradiente Canny	1300	12	20	50	120



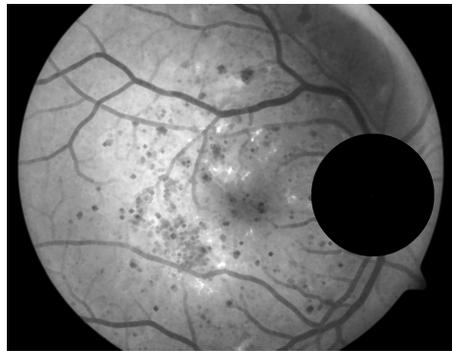
(a) Imagem005



(b) Imagem014



(c) Imagem015



(d) Imagem025

Figura 24: Resultado do pré-processamento.
Fonte: Autoria própria.

5.2.2 Implementação do algoritmo ABC

O código fonte do algoritmo ABC é disponibilizado por Karaboga (2005), e apenas alguns parâmetros devem ser determinados. Ao iniciar o algoritmo os valores destes parâmetros estabelecidos e testados empiricamente foram, 10 para a inicialização da colônia, 5 para o contador máximo de falhas, 500 para o ciclo de trabalho, 256 para os níveis de cinza e $[0,001$

0,1] para os limites referentes a área de detecção.

Quando se inicializa a colônia, os três tipos de abelhas são gerados. As abelhas empregadas (x_{ij}) são dispostas aleatoriamente no espaço da imagem em que, cada abelha é responsável por uma fonte de alimento inicial (i), que correspondem a *pixels* em um range de 256 níveis de cinza nas imagem.

A exploração dos *pixels* vizinhos a fonte inicial é gerada aleatoriamente para buscar *pixels* com maior intensidade luminosa. Ao implementar a Equação de aptidão, é calculada a probabilidade da fonte em que as abelhas empregadas consideram como a melhor.

Através das danças realizadas pelas abelhas empregadas, o recrutamento é gerado dispondo abelhas espectadoras no espaço da imagem para explorar as fontes com maior probabilidade de ser exsudatos. Na Figura 25, são ilustrados os resultados gerados pelo algoritmo artificial de abelhas, em que retornou como nível lógico alto 1 (branco), os *pixels* com maior intensidade luminosa.

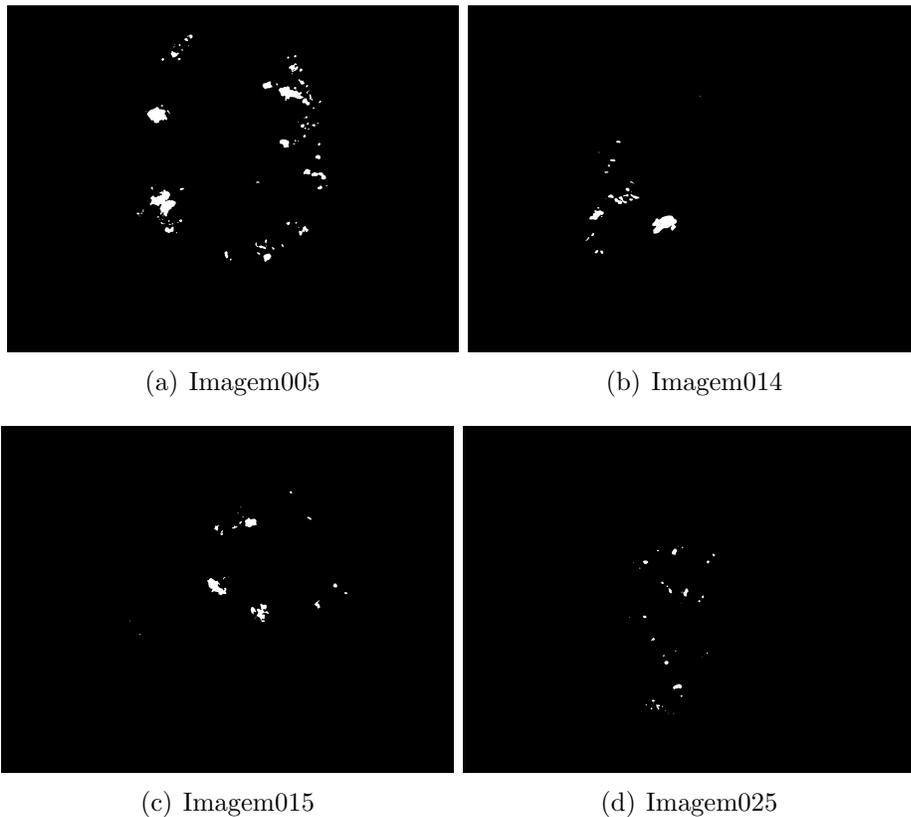


Figura 25: Resultado do algoritmo das abelhas.
Fonte: Autoria própria.

5.2.3 Pós-processamento

Para finalizar a detecção dos exsudatos é utilizado um pós-processamento nas imagens, pois o algoritmo implementado identifica os principais *pixels* com maior intensidade luminosa, que correspondem aos exsudatos. Os especialistas que realizaram os diagnósticos no banco de dados, englobam uma região além da patologia, não se preocupando em marcar o ponto exato que tem a doença. Assim, para o algoritmo proposto conseguir realizar uma detecção mais próxima do banco foi executada a operação morfológica de dilatação, sendo utilizado o elemento estruturante circular 9×9 . A Figura 26, mostra o resultado obtido após a etapa de pós-processamento aplicado na detecção dos exsudatos.

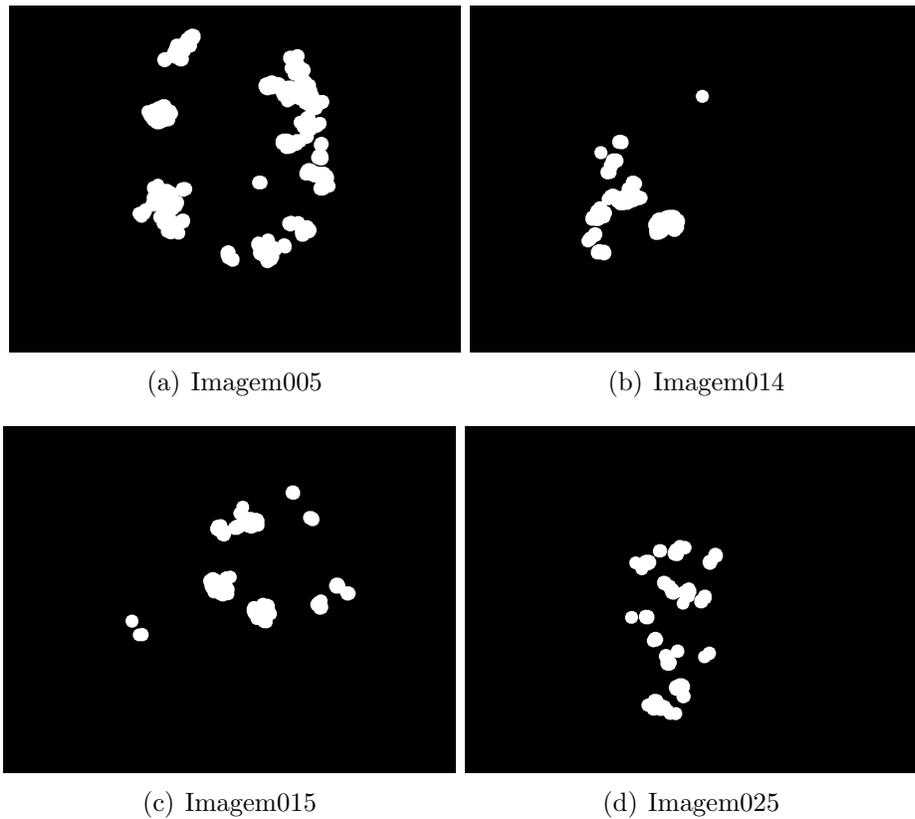


Figura 26: Resultado do pós-processamento aplicado na detecção dos exsudatos.

Fonte: Autoria própria.

Para avaliar o desempenho do algoritmo baseado na colônia artificial de abelhas foi executada a comparação das imagens geradas após o algoritmo ABC (representada pelas letras (b), (d), (f) e (h) da Figura 27), e as imagens do banco de dados da *Diaretdb1* referentes às letras (a), (c), (e) e (g). A escolha da área identificada pelos quatro especialistas deu-se

pela confiabilidade na precisão do diagnóstico, visto que, as variações de níveis de cinza das imagens correspondiam a incerteza quanto a presença de patologias.

Diversos testes foram executados com diferentes parâmetros, mas apenas o melhor resultado será exposto. A fim de detectar uma área maior que correspondam aos exsudatos, houve a necessidade de realizar uma alteração no número de colônia artificial de abelhas, o valor testado empiricamente foi 100, sendo realizada também uma nova dilatação com 25 interações. O resultado desta mudança pode ser observado na Figura 27.

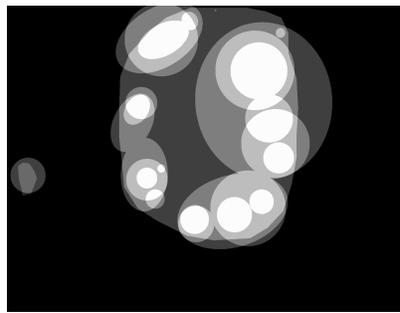
5.3 Detecção das microaneurismas

As microaneurismas, em imagens de fundoscopia, são caracterizadas por pequenos pontos avermelhados. Contudo, nas imagens do banco de dados outros artefatos com tonalidade e características semelhantes à patologia também podem ser encontrados. O uso de técnicas que removam ou minimizem estes artefatos, são necessárias para evitar a ocorrência de resultados falso positivos.

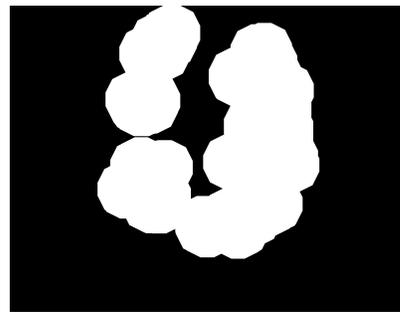
5.3.1 Pré-processamento

As imagens utilizadas para a detecção das microaneurismas foram as mesmas geradas na etapa de pré-processamento quando implementado na identificação dos exsudatos. Em escala de cinza, as imagens passaram pela etapa de suavização de suas bordas utilizando o filtro da média 3×3 com 10 interações, este foi implementado para realizar um leve borramento nas estruturas de veias e hemorragias, facilitando em um processo posterior. O resultado obtido no pré-processamento pode ser observado na Figura 28.

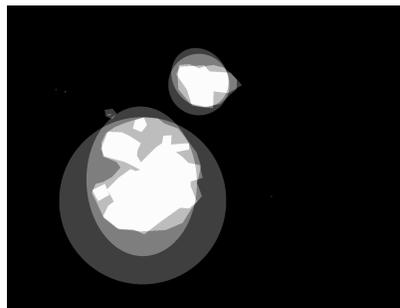
No bando de dados, foi observado que, em todas as imagens aparecem seis pontos, no mesmo local, com tonalidade e forma semelhantes as microaneurismas. Estes pontos são caracterizados como artefatos indesejáveis, provenientes das lentes de captura durante o exame de fundoscopia. Com base no exposto, surgiu a necessidade de se realizar um novo processamento que fosse capaz de eliminar estes artefatos. Nesse segundo pré-processamento foi realizada a marcação dos pontos referentes aos artefatos, em uma das imagens do banco de dados, pintando-os de branco com o auxílio do *software Paint*, como é ilustrada a imagem da Figura 29.



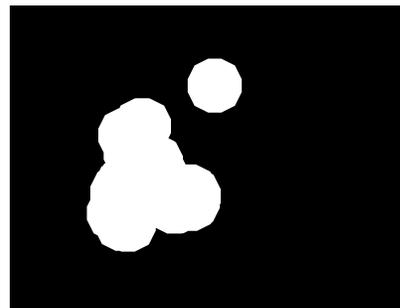
(a) Banco de dados imagem005



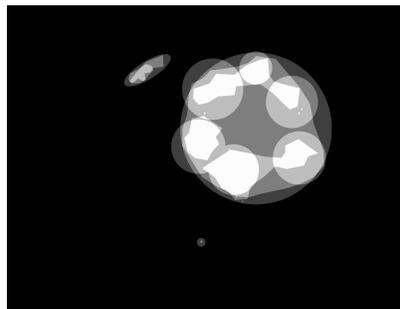
(b) Detecção na imagem005



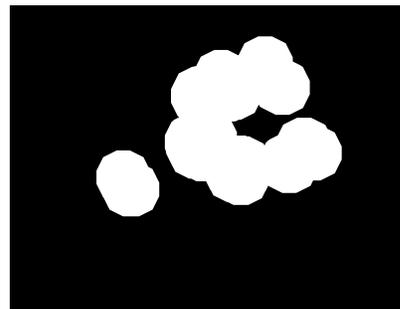
(c) Banco de dados imagem014



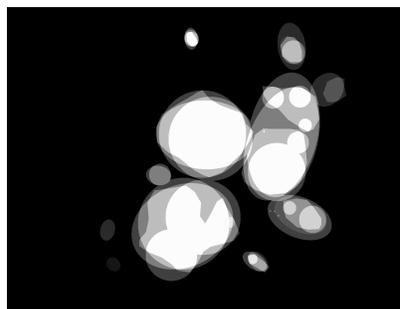
(d) Detecção na imagem014



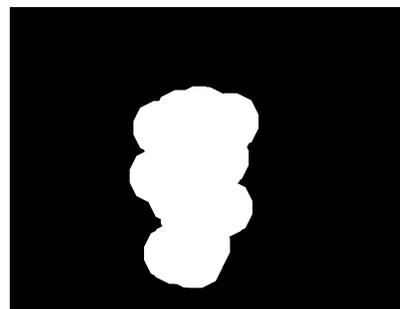
(e) Bando de dados imagem015



(f) Detecção na imagem015



(g) Banco de dados imagem025



(h) Detecção na imagem025

Figura 27: Comparação do banco de dados, com o último teste realizado com o algoritmo ABC.

Fonte: Autoria própria.

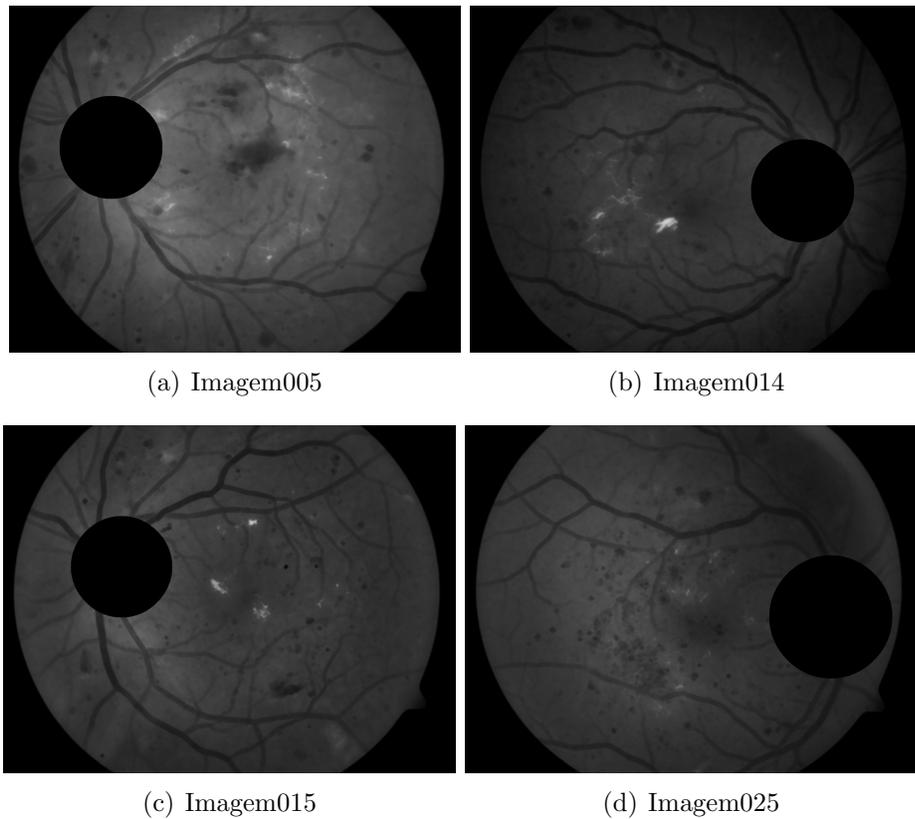


Figura 28: Resultado do pré-processamento aplicado na detecção das microaneurismas.
 Fonte: Autoria própria.



Figura 29: Marcação dos artefatos indesejáveis.
 Fonte: Autoria própria.

Em seguida, uma técnica de binarização foi implementada, os *pixels* que estavam anteriormente pintados de branco receberam a cor preta e os demais *pixels* da imagem ficaram com a cor branca. Esta binarização foi realizada com o intuito de eliminar das imagens os *pixels* referentes aos artefatos e deixar os demais *pixels* da imagem, criando assim, uma máscara. A Figura 30 ilustra o resultado obtido após a binarização da imagem que sofreu a

marcação dos artefatos.

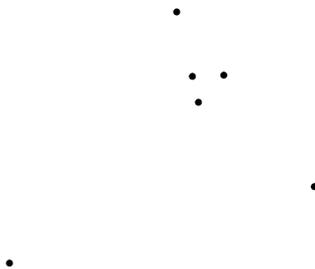


Figura 30: Binarização da imagem com a marcação de artefatos.

Fonte: Autoria própria.

Após a binarização, ilustrada na Figura 30, foi implementada uma multiplicação entre a máscara criada e as imagens do bando de dados, considerando que, ao realizar a multiplicação dos *pixels* pretos (valor 0) da máscara, eles irão excluir *pixels* na mesma posição na imagem do banco de dados, como mostra a Figura 31.

5.3.2 Processamento

As microaneurismas em todas as imagens do bando de dados da *Diaretdb1* apresentaram a mesma forma e tamanho. Com base nisso, surgiu a ideia de construir uma máscara com as mesmas características encontradas, para procurar nas imagens a patologia. Testada empiricamente, a matriz composta pela máscara possui 16 *pixels* de diâmetro, semelhante à patologia. A Figura 32 exemplifica o modelo utilizado na etapa de processamento.

Processo semelhante ao filtro da média, a máscara construída percorre toda a imagem em blocos, com dimensão de 16×16 *pixels*. Então, se na imagem houver alguma patologia com as mesmas características da máscara, esta região será pintada de branco possuindo a mesma dimensão da máscara, e os demais *pixels* receberam a cor preta.

Da mesma forma que foi realizada a comparação dos resultados obtidos na identificação dos exsudatos com o banco de dados, também ocorreu para as microaneurismas. Ao realizar a comparação entre as imagens foi considerada a área que três especialistas marcaram que haveria a patologia. Devido as diversas variações em tons de cinza, das imagens do banco de dados, foi realizada uma binarização das imagens referente a área em comum dos três

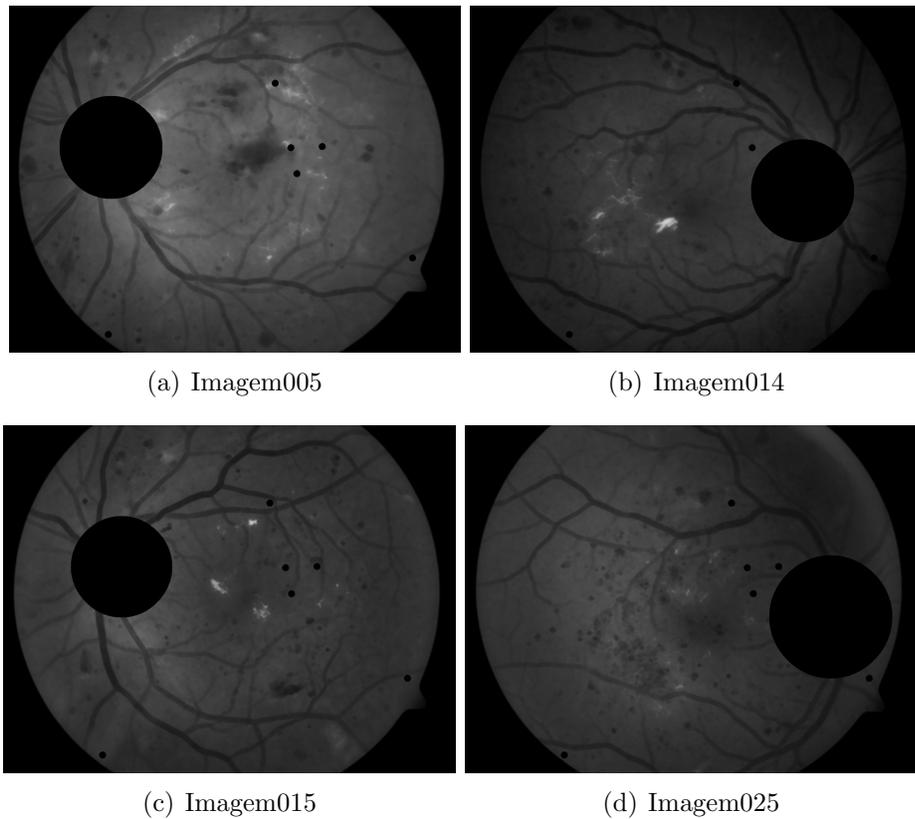


Figura 31: Multiplicação entre a máscara e as imagens.
 Fonte: Autoria própria.

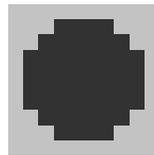


Figura 32: Modelo da microaneurisma, ampliada.
 Fonte: Autoria própria.

especialistas, deixando esta região com a cor branca. Na Figura 33 é ilustrado a comparação entre as imagens resultantes na etapa de processamento e as imagens do banco de dados.

5.3.3 Pós-processamento

Para concluir a detecção das microaneurismas é utilizado um pós-processamento nas imagens com a finalidade de obter um melhor resultado na detecção, visto que, os especialistas ampliam muito a área diagnosticada. Para aumentar a área referente as microaneurismas detectadas pelo algoritmo foi executada a operação morfológica de dilatação, sendo utilizado

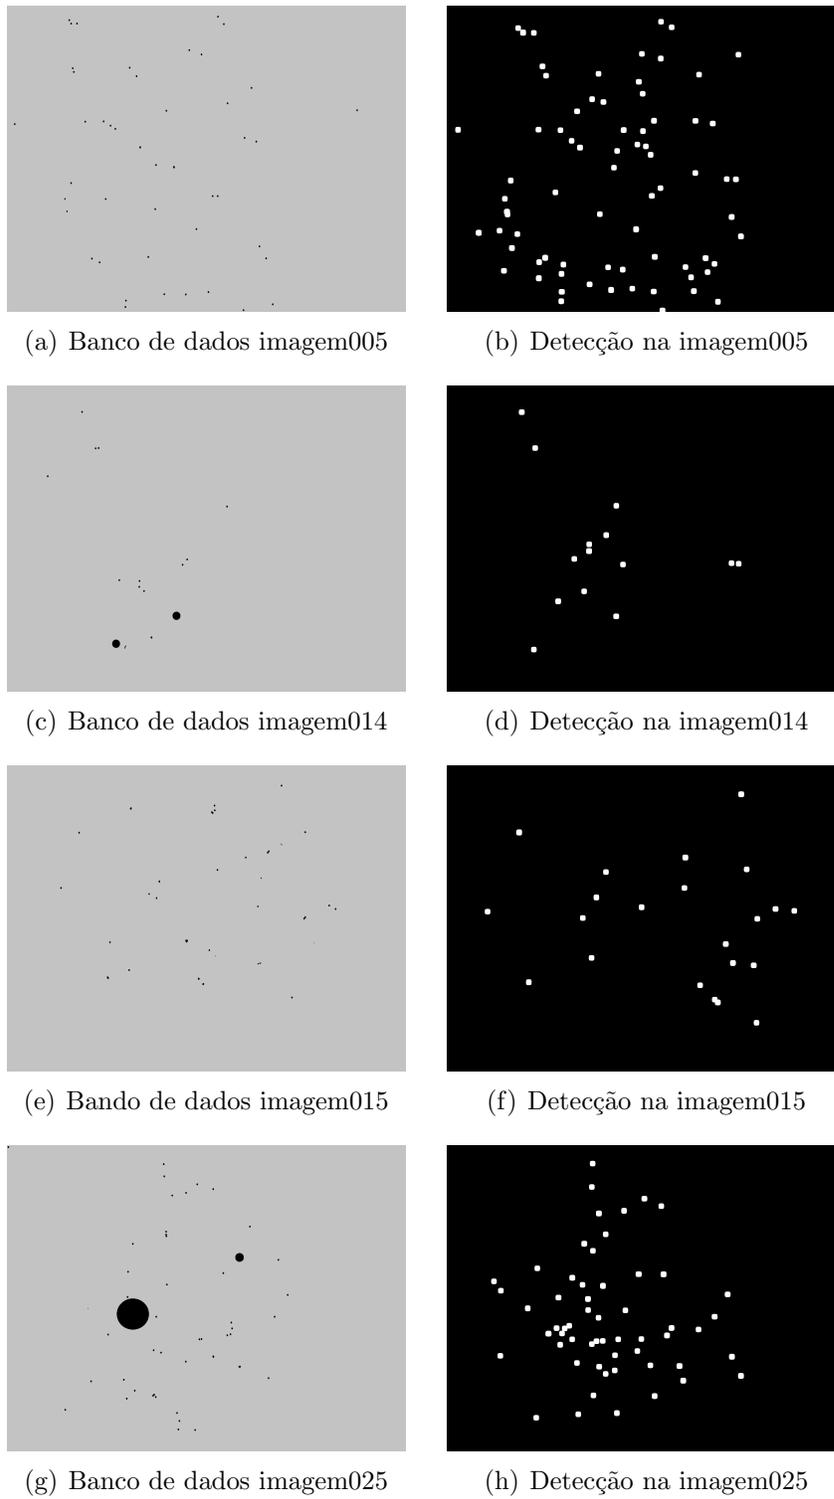


Figura 33: Comparação do banco de dados com o resultado da detecção das microaneurismas.
 Fonte: Autoria própria.

o elemento estruturante circular 9×9 . A Figura 34, mostra o resultado obtido após a etapa de pós-processamento aplicado na detecção das microaneurismas.

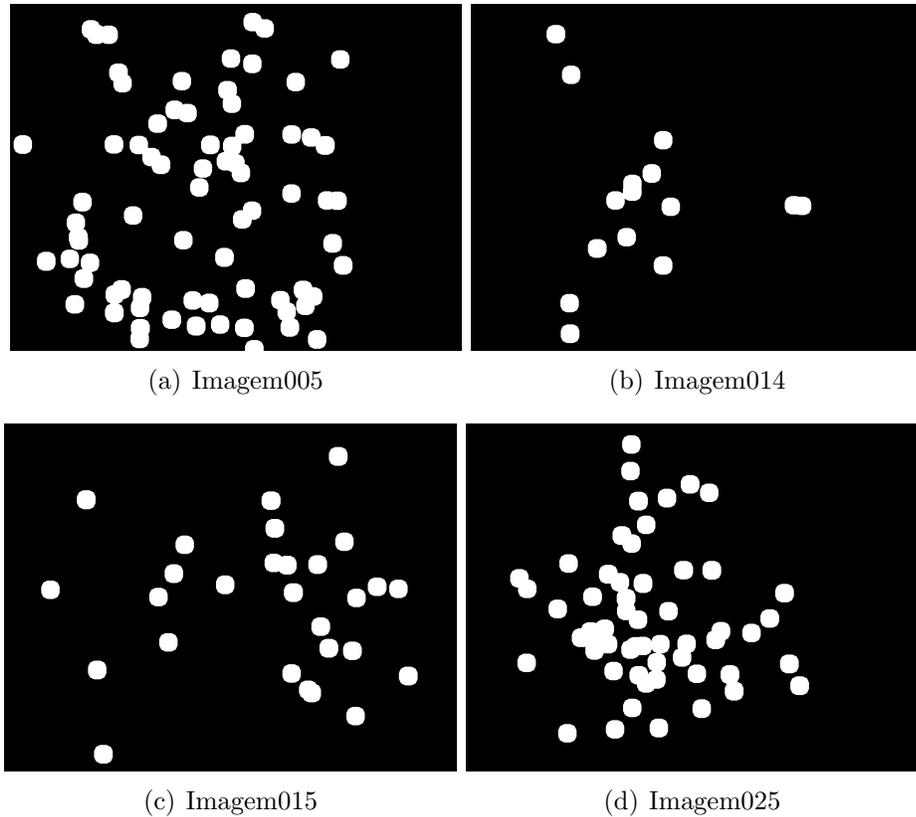


Figura 34: Resultado do pós-processamento aplicado na detecção dos exsudatos.
Fonte: Autoria própria.

A análise dos resultados obtidos após a operação morfológica de dilatação foi realizada com o auxílio dos avaliadores de algoritmos referentes à sensibilidade, especificidade e acurácia.

5.4 Validação dos algoritmos de detecção de patologias

Com base na literatura, os métodos de validação de algoritmos são relacionados as taxas de sensibilidade, especificidade e acurácia das imagens geradas, de acordo com as Equações 13, 14 e 15, respectivamente (Bagesteiro, 2017; Tan *et al.*, 2017).

- Sensibilidade: Percentual de diagnósticos anormais classificadas como anormais.

$$Sensibilidade = \frac{V_p}{V_p + F_n} \quad (13)$$

- Especificidade: Percentual de diagnósticos normais classificadas como normais.

$$Especificidade = \frac{V_n}{V_n + F_p} \quad (14)$$

- Acurácia: Refere-se ao grau em que o teste ou uma estimativa baseada em um teste é capaz de determinar o verdadeiro valor do que está sendo medido.

$$Acurácia = \frac{V_p + V_n}{V_p + V_n + F_p + F_n} \quad (15)$$

Em que, V_p é o número de *pixels* anormais detectados como anormal, V_n é o número de *pixels* normais detectadas como normais, F_p indica o número de *pixels* normais detectados como anormal (falso positivo) e F_n corresponde pelo número de *pixels* anormais detectados como normais (falso negativo).

6 Resultados Experimentais

Neste capítulo, serão expostos os resultados decorrentes da detecção dos exsudatos e microaneurismas, quanto aos valores coletados dos avaliadores de algoritmos.

6.1 Detecção dos exsudatos

Utilizando as imagens resultantes do pré-processamento, o algoritmo ABC retornou nível lógico alto para os *pixels* de maior intensidade, que caracterizam os exsudatos. Nas imagens do banco de dados, para comparação com o trabalho proposto, foi tomada como referência a área de análise em comum do diagnóstico dos quatro médicos especialistas, representada pela área branca.

A fim de validar o trabalho foram realizados os cálculos das taxas referentes à sensibilidade, especificidade e acurácia nas imagens. A média obtida no primeiro teste de detecção alcançou aproximadamente 38% de sensibilidade, 99% de especificidade e 97% de acurácia.

Ao analisar que a área detectada pelo algoritmo baseado na colônia artificial de abelhas foi consideravelmente pequena, mesmo após a dilatação realizada no pós-processamento, houve a necessidade de uma nova dilatação. Com o mesmo conjunto estruturante utilizado no primeiro pós-processamento, com o aumento para 10 iterações foi obtido um resultado melhor do que o anterior, alcançando 60% de sensibilidade, 97% de especificidade e 96% de acurácia. Com a realização de aperfeiçoamento das taxas de acurácia foi identificado que ao aumentar o número de iterações do processo de dilatação, o valor da sensibilidade das imagens eram superiores ao teste anterior, sendo assim, houve uma alteração do número de iterações para 20. Os dados coletados na terceira tentativa obtiveram uma média de 85% de sensibilidade, 93% de especificidade e 92% de acurácia, em comparação com as imagens do banco de dados da *Diaretdb1*, que correspondem pelo diagnóstico em comum de quatro especialistas.

Após a coleta de resultados surgiu a ideia de realizar a comparação das imagens resultantes, dos processamentos desenvolvidos, com o diagnóstico dos demais especialistas do banco de dados. Esta etapa de comparação foi definida com base no nível de cinza da imagem do banco de dados, composto pelo diagnóstico dos especialistas, sendo 59 o nível de

cinza referente ao diagnóstico de apenas um especialista, 119 referente a região de diagnóstico em comum de dois especialistas, 178 relativo ao nível de cinza do diagnóstico em comum de três especialistas e por fim, 237 refere-se ao nível de cinza que corresponde ao diagnóstico em comum dos quatro especialistas.

A Tabela 5, mostra os resultados obtidos pelas taxas de acurácia referente a região composta pelo diagnóstico dos médicos especialistas.

Tabela 5: Resultados da detecção dos *pixels* que representam os exsudatos quanto a região de diagnóstico dos especialistas.

Região de diagnóstico, banco de dados	Sensibilidade	Especificidade	Acurácia
Um especialista	56%	95%	93%
Dois especialistas	72%	94%	93%
Três especialistas	77%	93%	93%
Quatro especialistas	85%	93%	92%

Conforme os resultados coletados, quanto maior a área em comum de diagnósticos, maior é o valor da sensibilidade do algoritmo. Isto ocorre, pelo fato, da região detectada pelo algoritmo identificar apenas os *pixels* que são considerados a patologia. No momento em que se realiza a comparação das imagens resultantes com o banco de dados, são identificados os *pixels* em comum entre as duas imagens. Se a comparação for realizada com apenas o diagnóstico de um especialista, grande parte dos *pixels* do banco de dados serão desconsiderados, ocasionando uma baixa sensibilidade.

Em comparação com outros trabalhos que também realizaram a detecção dos exsudatos em imagens de retinopatia diabética, Tan *et al.* (2017) ao realizar a análise das imagens utilizadas no seu trabalho, obteve cerca de 87% de sensibilidade e 71% de especificidade. Seu resultado foi superior ao algoritmo proposto pelo uso de 10 camadas da rede neural convolutiva. Já o valor da sensibilidade alcançada nos trabalhos de Adalarasan & Malathi (2018) e Trigueiro (2015) se mostraram inferiores ao trabalho proposto. Ambos os autores não obtiveram os valores da acurácia nas imagens. Apenas Tan *et al.* (2017), calculou a especificidade nas imagens geradas no seu trabalho, como mostra a Tabela 10.

Conforme as imagens do bando de dados, referentes aos exsudatos, os especialistas identificaram que 48 dos 89 pacientes foram diagnosticados com a presença da patologia, e

Tabela 6: Comparação da detecção dos exsudatos com outros autores.

Autor	Sensibilidade	Especificidade	Acurácia
Trabalho Proposto	85%	93%	92%
Tan <i>et al.</i> (2017)	87%	71%	—
Adalarasan & Malathi (2018)	75%	—	—
Trigueiro (2015)	82%	—	—

41 pacientes foram considerados saudáveis. A Tabela 7 mostra a comparação entre o banco de dados e o trabalho proposto quanto ao número de pacientes com e sem a presença de exsudatos. Nas imagens do banco de dados, essa classificação foi definida da seguinte forma, se nas imagens houver o diagnóstico em comum de três a quatro especialistas este paciente tem a patologia, caso contrário, o paciente não tem patologia. A classificação das imagens resultantes das etapas de processamento é composta pela seguinte regra, se na imagem houver *pixels* brancos, o paciente tem a patologia, caso contrário, o paciente não tem patologia.

Tabela 7: Classificação das imagens quanto à presença ou não de exsudatos.

	Banco de dados	Algoritmo proposto
Tem patologia	48	52
Não tem patologia	41	37

6.2 Detecção das microaneurismas

Após a etapa de processamento as taxas de acurácia retornaram uma média de 33% de sensibilidade, 97% de especificidade e 98% de acurácia, tomando como base a área referente ao diagnóstico de três especialistas. Ao analisar que a área determinada pelo diagnóstico dos especialistas eram bem maiores que a patologia houve a necessidade de se realizar um pós-processamento, que no caso foi uma operação de dilatação.

Em seguida à operação de dilatação, taxas de acurácia alcançaram uma média de 75% de sensibilidade, 82% de especificidade e 81% de acurácia nas imagens, quando comparadas ao diagnóstico em comum de quatro médicos especialistas. A Tabela 8, mostra os resultados obtidos pelas taxas de acurácia referente a região composta pelo diagnóstico dos médicos especialistas.

Tabela 8: Resultados da detecção dos *pixels* que representam as microaneurismas quanto a região de diagnóstico dos especialistas.

Região de diagnóstico, banco de dados	Sensibilidade	Especificidade	Acurácia
Um especialista	47%	84%	80%
Dois especialistas	55%	85%	84%
Três especialistas	70%	80%	82%
Quatro especialistas	75%	82%	81%

Da mesma forma em que ocorreu uma variação do valor de sensibilidade das imagens, quando comparadas as diversas regiões de diagnósticos, também ocorreu quanto a detecção das microaneurismas. O melhor valor coletado das taxas de acurácia foi quando as imagens resultantes foram comparadas com as imagens de diagnóstico em comum dos quatro especialistas.

Em comparação com outros trabalhos, que também realizaram a detecção das microaneurismas em imagens de retinopatia diabética, o trabalho proposto manteve-se com o valor de sensibilidade igual ao trabalho de Adalarasan & Malathi (2018) e inferior aos demais trabalhos, como mostra a Tabela 9.

Tabela 9: Comparação da detecção das microaneurismas com outros autores.

Autor	Sensibilidade	Especificidade	Acurácia
Trabalho Proposto	75%	82%	81%
Rosas-Romero <i>et al.</i> (2015)	92%	93%	95%
Abràmoff <i>et al.</i> (2010)	90%	47%	43%
Tan <i>et al.</i> (2017)	87%	71%	————
Adalarasan & Malathi (2018)	75%	————	————

Como alternativa para a realização de uma triagem médica, foi desenvolvido um algoritmo que realizasse a classificação das imagens fundoscópicas quanto a presença ou não das microaneurismas. No algoritmo de classificação foram utilizadas as imagens resultantes da etapa de processamento, como sinal de entrada.

O algoritmo se comporta da seguinte forma, se a imagem de entrada houver a presença de *pixels* brancos, caracterizando a evidência de microaneurismas, é desenhado um quadrado verde no canto superior esquerdo das imagens originais do banco de dados. Caso não haja a presença de *pixels* brancos na imagem resultante do processamento é desenhado um qua-

drado vermelho no mesmo local do caso anterior. A Figura 35 ilustra como o algoritmo de classificação se comporta.

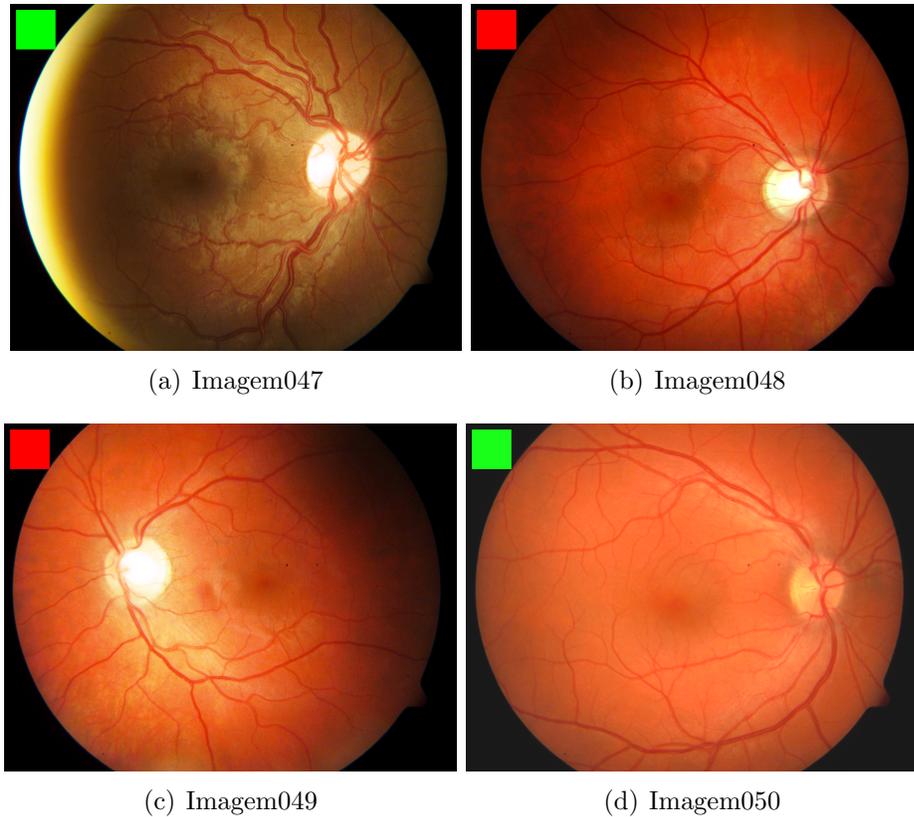


Figura 35: Exemplos das imagens classificadas quanto a presença de microaneurismas.
Fonte: Autoria própria.

A detecção das microaneurismas foi uma combinação de técnicas de processamento de imagens utilizando filtros de suavização, operadores morfológicos, busca por um padrão, segmentação de imagens, que culminaram na identificação desta patologia. A Tabela 10 mostra a comparação entre o banco de dados e o algoritmo proposto quanto ao número de pacientes identificados com e sem a presença de microaneurismas. Nas imagens do banco de dados, essa classificação foi definida da seguinte forma, se nas imagens houver o diagnóstico de um a quatro especialistas este paciente tem a patologia, caso contrário, o paciente não tem patologia. A classificação das imagens resultantes das etapas de processamento é composta pela seguinte regra, se na imagem houver *pixels* brancos, o paciente tem a patologia, caso contrário, o paciente não tem patologia.

Conforme o bando de dados da *Diaretdb1* 84 pacientes contêm a evidência de al-

Tabela 10: Classificação das imagens quanto à presença ou não de microaneurismas.

	Banco de dados	Algoritmo proposto
Tem patologia	71	75
Não tem patologia	18	14

guma patologia que caracterize a retinopatia diabética, e apenas 5 pacientes são considerados saudáveis, que não contêm sinais de retinopatia diabética segundo todos os especialistas que participaram da avaliação.

7 Conclusão

Neste trabalho foram implementados algoritmos para a detecção da retinopatia diabética, com a finalidade de, auxiliar os especialistas em medicina na tomada de decisão à respeito de um diagnóstico.

A vantagem de implementar o algoritmo bioinspirado na colônia artificial de abelhas, para a detecção de patologias, é a precisão o qual ele retorna. Diferentemente de uma binarização simples, utilizada em processamento digital de imagens, o algoritmo ABC é projetado para minimizar o erro, ou seja, ele retorna os principais *pixels* referentes a patologia.

Para a detecção dos exsudatos foram idealizados três algoritmos, sendo compostos por técnicas de processamento digital de imagens juntamente com o algoritmo ABC. Para a detecção das microaneurismas foram construídos três algoritmos compostos por técnicas de processamento de imagens. E o último algoritmo foi utilizado para classificar as imagens quanto a presença ou não das microaneurismas, como forma de realizar uma triagem médica.

Com a utilização das técnicas de processamento digital de imagens foi possível eliminar regiões que não correspondiam à região de interesse e, dessa forma, garantiu-se um resultado melhor e uma diminuição do custo computacional dos algoritmos de detecção, pois foram excluídas regiões que seriam processadas sem necessidade.

O algoritmo ABC implementado para a detecção dos exsudatos obteve resultados satisfatórios, visto que, o valor médio da taxa de acurácia referente à sensibilidade foi de 85%, ou seja, cerca de 85% da patologia foi identificada nas imagens de fundoscopia. Na etapa de detecção das microaneurismas, utilizando apenas técnicas de processamento digital de imagens, os valores coletados através dos avaliadores de algoritmos foram de 75% de sensibilidade.

Na etapa de classificação das microaneurismas, o trabalho proposto classificou quatro pacientes com a presença da patologia quando na verdade não tinham, e quatro sem a doença quando na verdade existiam, totalizando com um erro de 8 pacientes em um banco de dados com 89.

Em comparação a outros trabalhos que também realizaram a detecção de exsudatos e microaneurismas, em imagens de retinopatia diabética, o presente trabalho manteve-se na

média, com relação a taxa de sensibilidade. O objetivo geral do trabalho foi atingido, pois os algoritmos desenvolvidos conseguiram detectar as patologias que foram predefinidas para que eles detectassem, visando um algoritmo que realizasse a identificação automaticamente. Apesar de técnicas de segmentação de imagens baseadas em algoritmos de otimização bioinspirados aumentarem a cada dia, a aplicação do algoritmo bioinspirado na colônia artificial de abelhas utilizada para segmentar regiões referentes aos exsudatos, em imagens de retinopatia diabética, é inovadora.

7.1 Trabalhos futuros

Como propostas de trabalhos futuros são sugeridas a implementação de um novo algoritmo bioinspirado aplicado na detecção de hemorragias e microaneurismas, utilizando a limiarização de imagens. Assim como, a utilização de filtros para melhoria do contraste, na imagem de retinopatia diabética, para que as regiões de hemorragias possam ser detectadas. Utilização de outras bases de dados para realização dos testes com algoritmos já desenvolvidos neste trabalho, preferencialmente bases que apresentem uma incidência maior de casos de patologias, como em grandes grupos em setor de emergência hospitalar. Outra proposta é a análise da área macular, utilizando técnicas de processamento de imagens, por exemplo a busca por um padrão, como forma de mapear a evolução da retinopatia diabética. E por fim, a classificação das imagens quanto a presença ou não de exsudatos e hemorragias.

A Apêndice

Artigos Publicados:

- COSTA, A. E. M. F.; FALQUETO, A.; FREIRE, C. S.; ALBUQUERQUE, K. ; REGIS, C. D. M. . Identificação de Retinopatia Diabética Utilizando Processamento Digital de Imagens e Algoritmo Bioinspirado na Colônia Artificial de Abelhas. In: Sociedade Brasileira de Telecomunicações, 2018, Campina Grande. Anais do XXXVI Simpósio Brasileiro de Telecomunicações e Processamento de Sinais, 2018. v. XXXVI.
- COSTA, A. E. M. F.; REGIS, C. D. M. . Análise de técnicas de pós-processamento de imagens aplicada na detecção da retinopatia diabética. In: XXVI edição do Congresso Brasileiro de Engenharia Biomédica, 2018, Armação dos Búzios.. v. XXVI.

Referências

- Abràmoff, Michael D, Reinhardt, Joseph M, Russell, Stephen R, Folk, James C, Mahajan, Vinit B, Niemeijer, Meindert, & Quéllec, Gwénolé. 2010. Automated Early Detection Of Diabetic Retinopathy. *Ophthalmology*, **117**(6), 1147–1154.
- Adalarasan, R, & Malathi, R. 2018. Automatic Detection of Blood Vessels in Digital Retinal Images using Soft Computing Technique. *Materials Today: Proceedings*, **5**(1), 1950–1959.
- Aguiar, Cecília. 2017. *Avaliação de Acidente Vascular Cerebral em Tomografia Computadorizada Utilizando Algoritmo de Otimização de Formigas*. Dissertação (Engenharia Elétrica), IFPB (Instituto Federal de Educação, Ciência e Tecnologia da Paraíba), João Pessoa, Brazil.
- Aniche, Mauricio. 2009. *Fisiologia básica*. 1a edição edn.
- Bagesteiro, Luiza Dri. 2013. *Detecção de Lesões Vermelhas em Imagens do Fundo do Olho*. Monografia (Bacharel em Ciência da Computação), UNIPAMPA (Universidade Federal do Pampa), Alegrete, Brazil.
- Bagesteiro, Luiza Dri. 2017. *Algoritmo Bio-inspirado em Colônia de Abelhas Aplicado na Seleção de Características para Detecção de Desvios Vocais*. Dissertação (Engenharia Elétrica), IFPB (Instituto Federal de Educação, Ciência e Tecnologia da Paraíba), João Pessoa, Brazil.
- Chavez, Roger Larico, Iano, Yuzo, & Sablón, Vicente I Becerra. 2010. Localização Rápida da Íris do Olho Humano. *Revista Ciência e Tecnologia*, **9**(15).
- Conselho Brasileiro de Oftalmologia, CBO. 2013. Série Oftalmológica Brasileira. *São Paulo: Guanabara*.
- Conselho Brasileiro de Oftalmologia, CBO. 2014. Doenças Oculares. 1.
- Costa, José Alfredo Ferreira, *et al.* . 1999. *Classificação Automática e Análise de Dados por Redes Neurais Auto-organizáveis*. Ph.D. thesis.

- Costanzo, Linda S. 2011. *Fisiologia. Tradutor et al: Denise Costa Rodrigues et al.*
- Facon, Jacques. 2011. A morfologia Matemática e Suas Aplicações em Processamento de Imagens. *In: XXVII Congresso Regional de Iniciação Científica e Tecnologia em Engenharia*, vol. 13.
- Gonzalez, Rafael C, & Woods, RC. 2010. *Processamento Digital de Imagens. Tradução: Cristina Yamagami e Leonardo Piamonte.* São Paulo: Pearson Prentice Hall.
- Hassanien, Aboul Ella, Emary, Eid, & Zawbaa, Hossam M. 2015. Retinal Blood Vessel Localization Approach Based On Bee Colony Swarm Optimization, Fuzzy c-Means and Pattern Search. *Journal of Visual Communication and Image Representation*, **31**, 186–196.
- Hough, Paul VC. 1962 (Dec. 18). *Method and Means for Recognizing Complex Patterns.* US Patent 3,069,654.
- Jesus, Edison O, & Costa Jr, Roberto. 2015. A utilização de filtros gaussianos na análise de imagens digitais. *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics*, **3**(1).
- Kälviäinen, Rvjph, & Uusitalo, H. 2007. DIARETDB1 Diabetic Retinopathy Database and Evaluation Protocol. *Page 61 of: Medical Image Understanding and Analysis*, vol. 2007. Citeseer.
- Kapur, Jagat Narain, Sahoo, Prasanna K, & Wong, Andrew KC. 1985. A New Method for Gray-Level Picture Thresholding Using the Entropy of the Histogram. *Computer vision, graphics, and image processing*, **29**(3), 273–285.
- Karaboga, Dervis. 2005. *An Idea Based on Honey Bee Swarm for Numerical optimization.* Tech. rept. Technical report-tr06, Erciyes university, engineering faculty, computer engineering department.
- Karaboga, Dervis, & Basturk, Bahriye. 2007. A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm. *Journal of global optimization*, **39**(3), 459–471.

- Kurocama, Kazuhiro, Liu, Zhuolin, Crowell, James, Zhang, Furu, & Miller, Donald T. 2018. Method to Investigate Temporal Dynamics of Ganglion and Other Retinal Cells in the Living Human Eye. *Page 104740W of: Ophthalmic Technologies XXVIII*, vol. 10474. International Society for Optics and Photonics.
- Müller, Conrad George, & Rudolph, Mae. 1968. *Luz e Visão*. J. Olympio.
- Nakamura, Luis H. V. 2017. *Um Algoritmo de Colônia de Abelhas Artificial Auto-Adaptável Baseado no Melhor Global para Otimização Global*. Tese (Ciência da Computação e Matemática Computacional), Instituto de Ciências Matemáticas e de Computação, São Carlos, Brazil.
- Nunes, Fátima LS. 2006. Introdução ao Processamento de Imagens Médicas para Auxílio ao Diagnóstico. *Atualizações em Informática*, **1**, 73–126.
- Pedrini, Hélio, & Schwartz, William Robson. 2008. *Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações*. Thomson Learning.
- Polyak, Stephen Lucian. 1941. *The Retina*. Oxford, England: Univ. Chicago Press.
- Ramos, André. 2006. Fisiologia da Visão. *Um Estudo Sobre o “Ver” e o “Enxergar”. Análise do Simbólico no Discurso Visual, PUC (Universidade Católica do Rio de Janeiro), Brazil*.
- Rosas-Romero, Roberto, Martínez-Carballido, Jorge, Hernández-Capistrán, Jonathan, & Uribe-Valencia, Laura J. 2015. A Method to Assist in the Diagnosis of Early Diabetic Retinopathy: Image Processing Applied to Detection of Microaneurysms in Fundus Images. *Computerized medical imaging and graphics*, **44**, 41–53.
- Saba, Marcelo MF, & Epiphanyo, Ivan Dalla Valle e Ciências Quark, Clube. 2001. Dissecando um Olho de Boi para Entender a Óptica do Olho Humano. *Física na Escola*, **2**(2), 16–18.
- Silva, ROMUERE, Aires, K, Santos, T, Abdalla, K, & Veras, R. 2013. Segmentação, classificação e detecção de motociclistas sem capacete. *XI Simpósio Brasileiro de Automação Inteligente (SBAI), Fortaleza, Ceará–Brasil*.

- Sociedade Brasileira do Diabetes, DSBO. 2014. *Retinopatia Diabética*. Diretriz do Grupo Gen-AC Farmacêutica.
- Sopharak, Akara Uyyanonvara, Bunyarit Barman Sarah Williamson Thomas H. 2008. Automatic Detection of Diabetic Retinopathy Exudates from Non-Dilated Retinal Images Using Mathematical Morphology Methods. *Computerized Medical Imaging and Graphics*, **32**(8), 720 – 727.
- Tan, Jen Hong, Fujita, Hamido, Sivaprasad, Sobha, Bhandary, Sulatha V, Rao, A Krishna, Chua, Kuang Chua, & Acharya, U Rajendra. 2017. Automated Segmentation of Exudates, Haemorrhages, Microaneurysms Using Single Convolutional Neural Network. *Information Sciences*, **420**, 66–76.
- Tortora, Gerard J, & Derrickson, Bryan. 2016. *Corpo Humano-: Fundamentos de Anatomia e Fisiologia*. Artmed Editora.
- Trigueiro, M. A. L., Pedrosa V. D. Regis C. D. M. 2015. Análise de Imagens com Retinopatia Diabética para Identificação de Exsudatos Duros. *Simpósio Brasileiro de Telecomunicações*, 2.
- Zhang, Xiwei, Thibault, Guillaume, Decencièrre, Etienne, Marcotegui, Beatriz, Laÿ, Bruno, Danno, Ronan, Cazuguel, Guy, Queller, Gwénolé, Lamard, Mathieu, Massin, Pascale, *et al.* . 2014. Exudate detection in color retinal images for mass screening of diabetic retinopathy. *Medical image analysis*, **18**(7), 1026–1043.
- Zhang, Yudong, Wu, Lenan, & Wang, Shuihua. 2011. Magnetic resonance brain image classification by an improved artificial bee colony algorithm. *Progress In Electromagnetics Research*, **116**, 65–79.