



UNIVERSIDADE FEDERAL DO PAMPA
CIÊNCIA DA COMPUTAÇÃO

LUIZA DRI BAGESTEIRO

**DETECÇÃO DE LESÕES VERMELHAS EM IMAGENS DE FUNDO DO
OLHO**

Trabalho de Conclusão de Curso

Alegrete
2013

LUIZA DRI BAGESTEIRO

**DETECÇÃO DE LESÕES VERMELHAS EM IMAGENS DE FUNDO DO
OLHO**

Trabalho de Conclusão de Curso apresentado
como parte das atividades para obtenção do
título de bacharel em Ciência da Computação
na Universidade Federal do Pampa.

Orientador: Prof. Dr. Daniel Welfer

**Alegrete
2013**

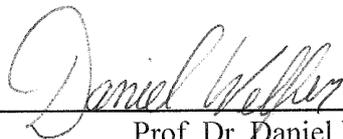
LUIZA DRI BAGESTEIRO

**DETECÇÃO DE LESÕES VERMELHAS EM IMAGENS DE FUNDO DO
OLHO**

Trabalho de Conclusão de Curso apresentado
como parte das atividades para obtenção do
título de bacharel em Ciência da Computação
na Universidade Federal do Pampa.

Trabalho apresentado e aprovado em: 06 de Março de 2013.

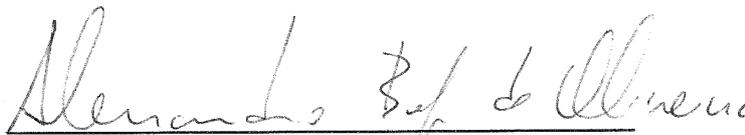
Banca examinadora:



Prof. Dr. Daniel Welfer

Orientador

Ciência da Computação – UNIPAMPA



Prof. Me. Alessandro Bof de Oliveira

Ciência da Computação – UNIPAMPA



Profª. Me. Patrícia Rodrigues da Silva

Ciência da Computação – UNIPAMPA

Dedico este trabalho aos meus amados pais

Luiz Carlos e Rosana

AGRADECIMENTOS

Primeiramente, agradeço a minha família, por me apoiarem em todos os momentos da minha vida, e principalmente por acreditarem em mim.

Agradeço ao meu orientador, Prof. Daniel Welfer, pela paciência, auxílio, incentivo e pelos conselhos dados, pois além de orientador, foi também um amigo.

A todos aqueles que foram meus professores na Computação, por contribuírem na minha formação.

Aos meus amigos que nunca deixaram de me incentivar. E também ao Ricardo, pela paciência e companheirismo.

Por fim, agradeço a todos que contribuíram de alguma forma na realização deste trabalho.

RESUMO

A avaliação da retina pode fornecer informações sobre a presença de doenças oculares tais como glaucoma e degeneração macular. Além disso, doenças sistêmicas crônicas, tais como pressão arterial elevada e diabetes também podem ser detectadas através das condições da retina. A detecção de lesões vermelhas em imagens de fundo do olho possui inúmeras aplicações relevantes, pois podem revelar doenças que ainda não causaram sintomas. Dessa forma, o presente trabalho tem como objetivo detectar automaticamente lesões vermelhas em imagens de fundo do olho. O método proposto utiliza morfologia matemática e possui duas etapas, denominadas: a) detecção preliminar e b) detecção refinada das lesões vermelhas. A etapa de detecção preliminar detecta estruturas escuras da retina, como lesões vermelhas, vasos sanguíneos e fóvea. Por sua vez, a detecção refinada objetiva melhorar a detecção das lesões vermelhas detectadas na etapa anterior. O método desenvolvido alcançou 75.82% de sensibilidade e 93.49% de especificidade no estágio de detecção refinada utilizando um banco de imagens público. Isso mostra que o método poderia ser útil em um sistema de triagem real, podendo auxiliar no trabalho de especialistas em oftalmologia.

Palavras-chave: processamento de imagens, morfologia matemática, lesões vermelhas, imagens de fundo do olho.

ABSTRACT

Evaluation of the retina can provide information regarding the presence of ocular diseases such as glaucoma and macular degeneration. Moreover, chronic systemic diseases such as high blood pressure and diabetes can also be detected through of the retina conditions. The red lesions detection in eye fundus images has many relevant applications because they may reveal diseases that still caused no symptoms. Thus, the present paper aims to automatically detect red lesions in eye fundus images. Our proposed method uses mathematical morphology and has two steps, namely: a) coarse detection and b) fine detection of red lesions. The coarse detection step detects dark structures of the retina, such as red lesions, blood vessels and fovea. On the other hand, the fine detection aims to improve the detection of red lesions detected in the previous step. The method achieved a mean sensitivity of 75.82% and a mean specificity of 93.49% in the fine detection step using a publicly available database. This demonstrates that the method could be useful in a real screening system, and may assist the work of experts in ophthalmology.

Keywords: image processing, mathematical morphology, red lesions, eye fundus images.

LISTA DE FIGURAS

Figura 1.1 - Lesões vermelhas na imagem da retina	26
Figura 1.2 - Tipos distintos de lesões vermelhas presentes na retina	28
Figura 1.3 - Estruturas presentes na retina	29
Figura 1.4 - Microaneurismas e hemorragias em imagem da retina	30
Figura 1.5 - Sequência resumida de problemas da detecção das lesões vermelhas.....	32
Figura 1.6 - Diagrama de atividades para o método de detecção desenvolvido.....	33
Figura 3.1 - Elementos estruturantes presentes no MMORPH	41
Figura 3.2 – Operações tons de cinza de dilatação, erosão, abertura e fechamento.....	43
Figura 3.3 - Operações binárias de dilatação, erosão, abertura e fechamento.....	46
Figura 4.1 - <i>Ground truth</i> das imagens do DIARETDB1	48
Figura 4.2 - Diferença entre os três canais de uma imagem.....	49
Figura 4.3 - Imagens resultantes de cada passo da detecção preliminar	54
Figura 4.4 - Passos resumidos para detectar os candidatos à lesão	55
Figura 4.5 - Imagens resultantes de cada passo da detecção refinada.....	59
Figura 4.6 - Passos resumidos para detectar o conjunto final das lesões vermelhas.....	60
Figura 5.1 - Áreas usadas para encontrar as medidas utilizadas	63
Figura 5.2 - Detecção de VP, FN, FP e VN nas detecções preliminar e refinada.....	67
Figura 5.3 - Problemas na detecção e remoção dos vasos sanguíneos	69
Figura 5.4 - Problema na remoção da região da fóvea	70
Figura 5.5 - Problemas com lesões vermelhas na região da fóvea.....	71

LISTA DE TABELAS

Tabela 1.1 - Escala internacional de gravidades da Retinopatia Diabética.....	27
Tabela 2.1 - Resultados obtidos para os métodos propostos na literatura.....	39
Tabela 5.1 - Média de VP, FN, FP e VN nos estágios de detecção preliminar e refinada.....	65
Tabela 5.2 - Resultados do método nos estágios de detecção preliminar e refinada.....	66
Tabela 5.3 - Tempo médio de processamento por imagem.....	66

LISTA DE SIGLAS

FN – Falso Negativo

FP – Falso Positivo

FSA – Filtros Sequenciais Alternados

RD – Retinopatia Diabética

RDNP – Retinopatia Diabética Não-Proliferativa

RDP – Retinopatia Diabética Proliferativa

RH – Retinopatia Hipertensiva

VN – Verdadeiro Negativo

VP – Verdadeiro Positivo

LISTA DE SÍMBOLOS

δ – Dilatação morfológica

ε – Erosão morfológica

γ – Abertura morfológica

ϕ – Fechamento morfológico

$\mathcal{R}_g(f)$ – Reconstrução morfológica por dilatação da imagem marca f condicionada à imagem máscara g

$\mathcal{R}_g^*(f)$ – Reconstrução morfológica por erosão da imagem marca f condicionada à imagem máscara g

$RMAX$ – Operador de máximos regionais

$RMIN$ – Operador de mínimos regionais

$Hmax$ – Filtro H -maxima

$Hmin$ – Filtro H -minima

SUMÁRIO

1	INTRODUÇÃO	25
1.1	Motivação	26
1.2	Objetivos	30
1.3	Descrição do problema	31
1.4	Método de trabalho	32
1.5	Organização do documento	33
2	TRABALHOS RELACIONADOS	35
2.1	Métodos propostos na literatura para detectar lesões vermelhas	35
2.2	Comparativo entre trabalhos relacionados	38
2.3	Conclusão	39
3	FUNDAMENTOS DE MORFOLOGIA MATEMÁTICA	41
4	MATERIAIS E MÉTODOS PARA A DETECÇÃO DE LESÕES	47
4.1	Materiais	47
4.2	Método para a detecção preliminar das lesões vermelhas	49
4.3	Método para a detecção refinada das lesões vermelhas	55
4.4	Conclusão	60
5	RESULTADOS EXPERIMENTAIS	63
5.1	Medidas utilizadas para a quantificação do método	63
5.2	Resultados da detecção automática de lesões vermelhas	64
5.3	Conclusão	71
6	CONSIDERAÇÕES FINAIS	73
	REFERÊNCIAS	75
	APÊNDICE A – Imagens que tiveram seu <i>ground truth</i> modificado	79
	APÊNDICE B – Resultado da detecção preliminar em cada imagem com lesão	81
	APÊNDICE C – Resultado da detecção preliminar em cada imagem sem lesão	83
	APÊNDICE D – Resultado da detecção refinada em cada imagem com lesão	85
	APÊNDICE E – Resultado da detecção refinada em cada imagem sem lesão	87
	APÊNDICE F – Tempo de processamento de cada imagem	89

1 INTRODUÇÃO

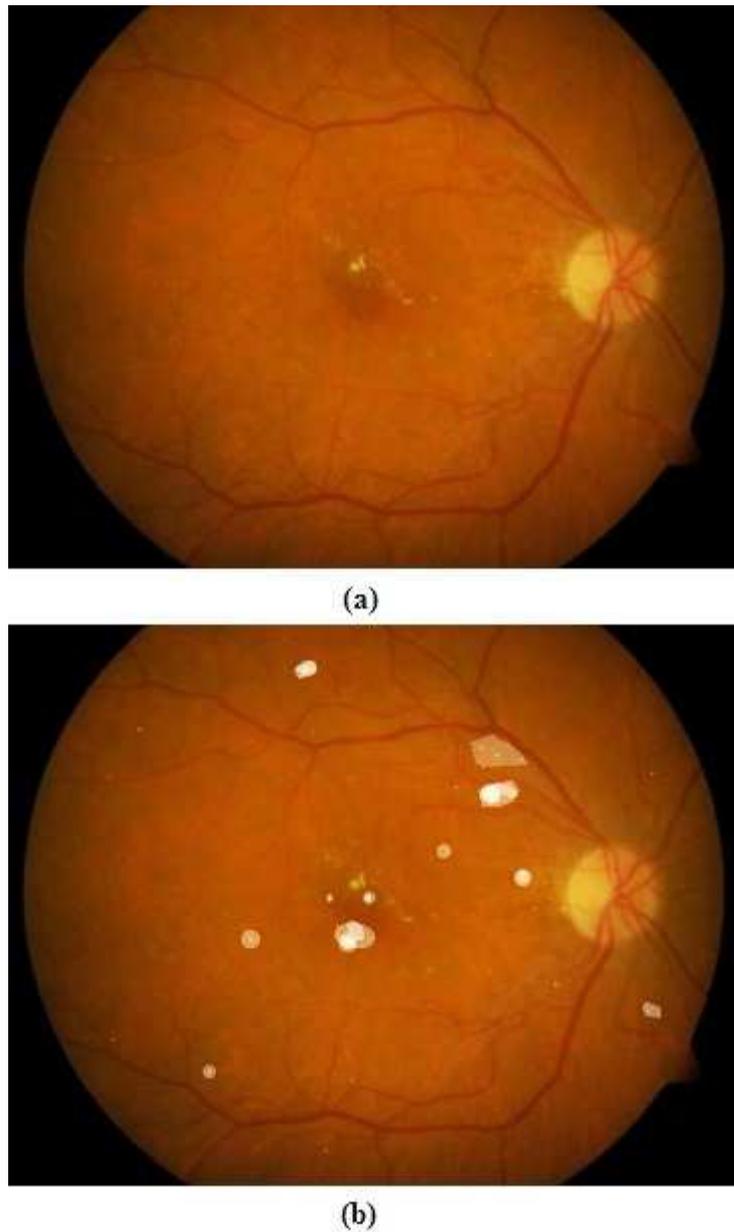
A retina é uma camada de tecido que reveste o interior do olho, permitindo a observação direta não-invasiva da circulação. Existem doenças oculares e sistêmicas que se manifestam na retina. As doenças oculares incluem glaucoma e degeneração macular, já as doenças sistêmicas incluem a Retinopatia Diabética (RD) e a Retinopatia Hipertensiva (RH), oriundas do diabetes e da hipertensão, respectivamente, além de esclerose múltipla (ABRÀMOFF; GARVIN; SONKA, 2010). Alguns sintomas dessas doenças aparecem na retina na forma de lesões brancas ou vermelhas.

As lesões brancas, denominadas exsudatos, são depósitos de lipídio de cor branca ou amarela, que podem ser duros ou algodonosos (WALTER et al., 2002). Lesões vermelhas, por sua vez, normalmente são microaneurismas ou hemorragias, que são sinais típicos de diabetes, hipertensão e outras doenças da retina, além de ser o principal indicador da RD. Se, por um lado, a retina é vulnerável a diversas doenças, por outro lado a análise das imagens da retina permite que doenças sejam detectadas, diagnosticadas e tratadas (ABRÀMOFF; GARVIN; SONKA, 2010). A Figura 1.1 (a) mostra uma imagem da retina que possui pequenas lesões vermelhas. A Figura 1.1 (b) mostra a mesma imagem, porém com as lesões vermelhas delimitadas por quatro especialistas em oftalmologia (KAUPPI et al., 2007).

Assim, é importante realizar a detecção de lesões vermelhas na retina, pois elas podem revelar doenças que ainda não causaram sintomas, ou seja, a detecção de lesões vermelhas é um mecanismo para a detecção precoce de doenças como a RD (CIULLA; AMADOR; ZINMAN, 2003). É dentro desse contexto que o presente trabalho é introduzido, tendo como objetivo detectar automaticamente lesões vermelhas em imagens de fundo do olho.

Este capítulo apresenta na seção 1.1 a motivação para o trabalho realizado. Na seção 1.2 descreve-se detalhadamente o objetivo geral e os objetivos específicos. Na seção 1.3 é apresentada a descrição do problema da detecção de lesões vermelhas. A seção 1.4 apresenta o método de trabalho. Por fim, na seção 1.5 é apresentada uma descrição sucinta dos demais capítulos.

Figura 1.1 - Lesões vermelhas na imagem da retina



Delimitando as lesões vermelhas na imagem: (a) Imagem original com as lesões vermelhas; (b) Imagem cujas lesões vermelhas foram identificadas manualmente por especialistas em oftalmologia (KAUPPI et al., 2007).

1.1 Motivação

Uma das principais causas de cegueira na população ativa, isto é, em idade de trabalho, da maioria dos países desenvolvidos é o diabetes. O diabetes é uma doença que está associada a altas taxas de tempo de trabalho perdido, incapacidade temporária e morte prematura. Estima-se que, em 2002, essa incapacidade temporária teve um impacto econômico nos EUA de US\$ 40 bilhões, devido à perda de produtividade no trabalho dos portadores da doença (AMERICAN DIABETES ASSOCIATION, 2003). No entanto, essas

estimativas não levam em consideração que os custos do diabetes para o indivíduo e sua família não são apenas financeiros, pois há o custo da dor e sofrimento que acarretam na redução da qualidade de vida (WORLD HEALTH ORGANIZATION; INTERNATIONAL DIABETES FEDERATION, 2004).

Uma das complicações do diabetes é a RD, que é a responsável por causar a cegueira nas pessoas em idade de trabalho (WORLD HEALTH ORGANIZATION, 2005). A RD é uma complicação microvascular que causa alterações na retina, e na pior das hipóteses, cegueira. (KAUPPI et al., 2007). Tipicamente, a RD tem pouco ou nenhum sintoma nos estágios iniciais da doença, até ocorrer perda visual (CIULLA; AMADOR; ZINMAN, 2003), (FONG et al., 2003). Para prevenir a perda da capacidade de visão, é importante detectar a RD e tratar pacientes no início da doença.

A RD é uma doença progressiva que apresenta as seguintes etapas: RD não aparente, RD não-proliferativa (RDNP), e RD proliferativa (RDP). A Tabela 1.1 mostra uma escala internacional de gravidades da RD, e o que caracteriza cada nível de gravidade (CIULLA; AMADOR; ZINMAN, 2003).

Tabela 1.1 - Escala internacional de gravidades da Retinopatia Diabética

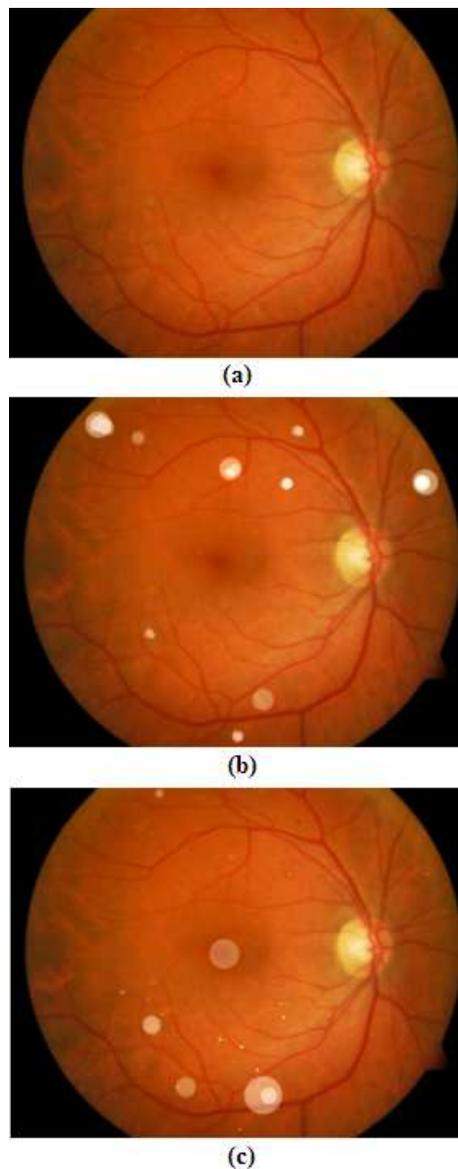
Nível de gravidade	Característica
Retinopatia diabética não aparente	Sem anomalias
RDNP leve	Microaneurismas
RDNP moderada	Mais do que apenas microaneurismas, e menos que a RDNP grave
RDNP grave	Qualquer um dos seguintes, e sem sinais de RDP: <ul style="list-style-type: none"> • Mais de vinte hemorragias intra-retinianas em cada um dos quatro quadrantes • Deformação dos vasos em dois ou mais quadrantes • Anomalias microvasculares intra-retinianas em um ou mais quadrantes
RDP	Um ou ambos dos seguintes: <ul style="list-style-type: none"> • Neovascularização • Hemorragia vítrea ou pré-retiniana

Fonte: Ciulla et al. (2003)

A detecção de lesões vermelhas tem inúmeras aplicações relevantes. Conforme visto na Tabela 1.1, microaneurismas estão presentes na RD leve e também na RD moderada. Já as hemorragias compõem os sinais da RD grave. Ou seja, a presença de microaneurismas caracteriza o início da doença e a presença de hemorragias mostra que a doença já está em um

nível mais avançado. Dessa forma, detectar essas lesões auxilia no diagnóstico de pacientes com diabetes que podem estar nos estágios iniciais da RD, podendo iniciar um tratamento para retardar a progressão da doença, assim como serve para revelar casos graves de RD. Também pode ajudar o especialista a identificar pacientes que necessitam de tratamento com mais urgência. Na Figura 1.2 é possível visualizar os dois tipos distintos de lesões vermelhas (microaneurismas e hemorragias), onde a Figura 1.2 (a) é uma imagem da retina que contém microaneurismas e hemorragias. A Figura 1.2 (b) mostra apenas as marcações das hemorragias, e na Figura 1.2 (c) são marcados apenas os microaneurismas.

Figura 1.2 - Tipos distintos de lesões vermelhas presentes na retina



(a) Imagem original com as lesões vermelhas; (b) Marcação das hemorragias feita por especialistas em oftalmologia (KAUPPI et al., 2007); (c) Marcação dos microaneurismas feita por especialistas em oftalmologia (KAUPPI et al., 2007).

No entanto, a detecção dessas lesões vermelhas ainda é difícil por diversas razões. Primeiramente porque microaneurismas e hemorragias possuem vários tamanhos e formas, sendo difícil realizar a detecção de todos eles na imagem, mas principalmente porque as estruturas normais da retina como a fóvea e os vasos sanguíneos, podem ser confundidas com lesões (ABRÀMOFF; GARVIN; SONKA, 2010). A Figura 1.3 ilustra essas estruturas. Além disso, algumas lesões vermelhas ficam muito próximas dos vasos sanguíneos, dificultando a distinção entre eles. As hemorragias de tamanho maior são da mesma cor dos vasos, diferenciando-se apenas na forma geométrica, porém microaneurismas e hemorragias menores possuem cor, textura e geometria muito semelhantes à estrutura dos vasos sanguíneos (SILBERMAN et al., 2010). Na Figura 1.4 é possível perceber que os microaneurismas, por exemplo, são lesões sutis, isto é, ocupam uma área em pixels muito pequena e, portanto, difícil de ser detectada com precisão.

Dessa forma, detectar manualmente essas lesões é um processo demorado e suscetível a erros, mesmo para um especialista treinado (JAAFAR; NANDI; AL-NUAIMY, 2011).

Figura 1.3 - Estruturas presentes na retina

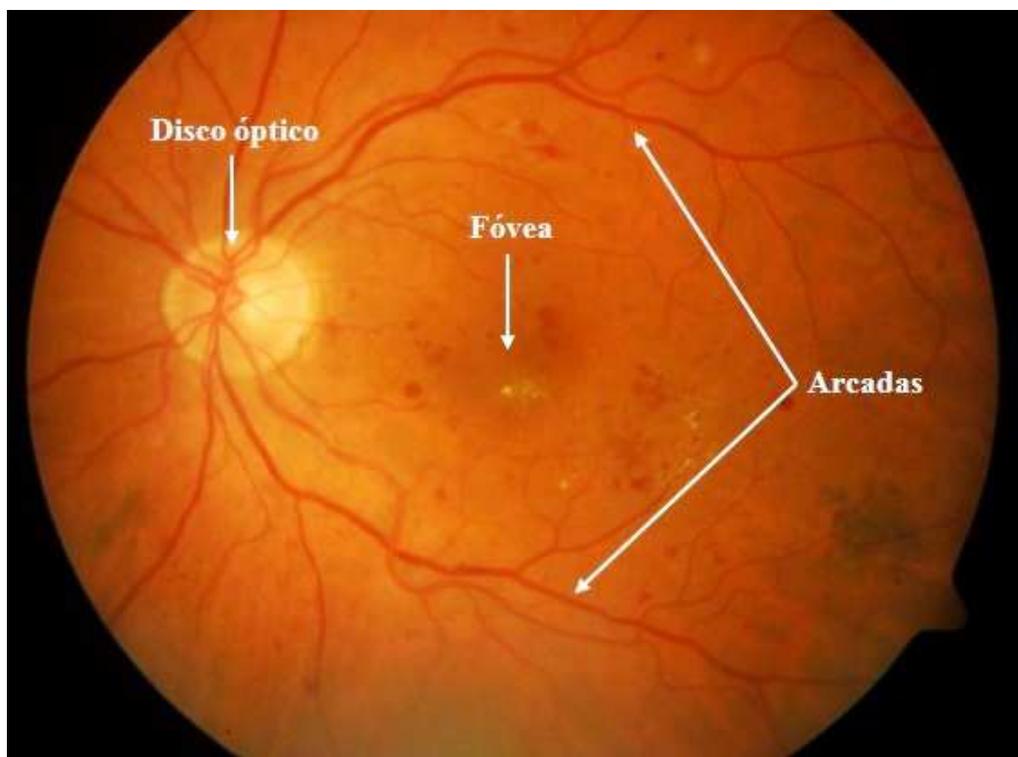
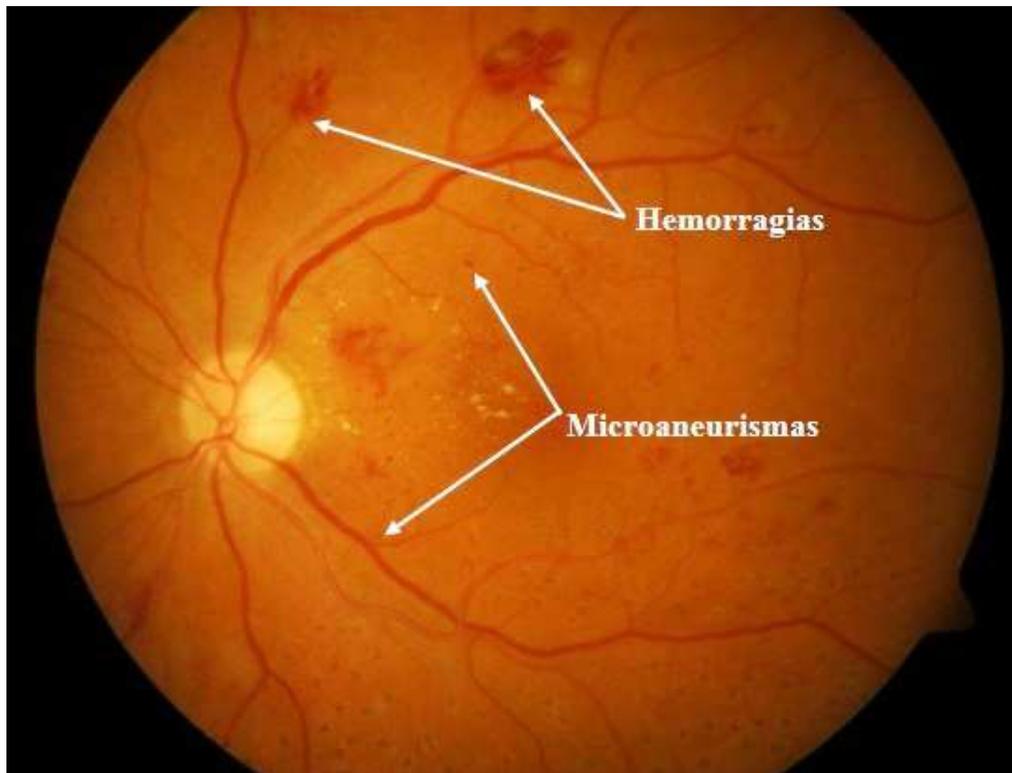


Figura 1.4 - Microaneurismas e hemorragias em imagem da retina



1.2 Objetivos

Diante da motivação apresentada anteriormente, o presente trabalho tem como objetivo geral realizar a detecção automática de lesões vermelhas (microaneurismas e hemorragias) em imagens de fundo do olho. Entre os objetivos específicos, podemos citar os seguintes:

- Utilizar imagens de fundo do olho e técnicas de processamento e análise de imagens para identificar automaticamente lesões vermelhas;
- Utilizar o banco de imagens público de fundo de olho DIARETDB1 (KAUPPI et al., 2007);
- Discriminar lesões vermelhas de vasos sanguíneos e outras estruturas presentes na retina;
- Quantificar a detecção das lesões vermelhas com base em medidas de sensibilidade, especificidade e outras medidas;
- Comparar os resultados obtidos com os demais métodos estudados, com a finalidade de obter resultados iguais ou superiores;

- Comparar os resultados obtidos com a detecção manual realizada por um especialista (*ground truth*).

É importante deixar claro que o objetivo deste trabalho não é detectar o grau de severidade da RD, e sim apenas detectar e analisar a presença ou ausência das lesões vermelhas em imagens de fundo do olho. Da mesma forma, cabe observar que não é feita nenhuma distinção entre hemorragias e microaneurismas na detecção automática das lesões vermelhas.

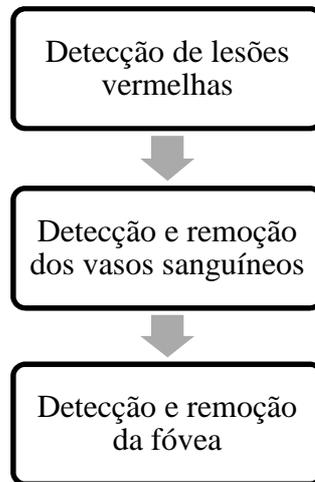
1.3 Descrição do problema

O problema deste trabalho consiste na detecção de lesões vermelhas em imagens de fundo do olho. Realizar essa detecção não é uma tarefa simples, pois envolve uma série de problemas descritos abaixo:

1. Detecção de lesões vermelhas: é difícil realizar a detecção de todas as lesões em uma imagem, pois, como dito anteriormente, existem certas lesões que ocupam uma área muito pequena em pixels, ou são lesões sutis, o que dificulta a detecção de todas elas na imagem;
2. Detecção e remoção dos vasos sanguíneos: esse problema consiste na detecção de todos os vasos da retina, para posterior remoção deles da imagem. Os vasos das arcadas, devido ao seu tamanho e largura, ainda conseguem ser detectados com mais facilidade, mas os vasos capilares possuem tamanho e largura muito pequenos. Como eles possuem a mesma intensidade que as lesões vermelhas, eles acabam não sendo removidos, fazendo parte dos falsos positivos (pixels incorretamente detectados como sendo lesão). Outro problema é que muitas lesões vermelhas, de diversos tamanhos, ficam muito próximas dos vasos, dificultando a extração dos vasos sem que ocorra a perda dessas lesões;
3. Detecção e remoção da fóvea: o problema de detecção da região da fóvea pode ser eliminado utilizando um bom método que detecte essa estrutura, porém, se a fóvea não for localizada corretamente, ou seja, se ela acabar sendo confundida com uma lesão vermelha semelhante à sua estrutura, a lesão será removida, e não a fóvea. Isso diminui a sensibilidade do método.

Assim, o problema a ser resolvido consiste de três etapas, como pode ser visto na Figura 1.5.

Figura 1.5 - Sequência resumida de problemas da detecção das lesões vermelhas



1.4 Método de trabalho

Para atingir os objetivos citados na Seção 1.2, estabeleceu-se o método de trabalho abaixo descrito:

- Análise e estabelecimento de uma solução para o problema, baseado no estudo dos trabalhos relacionados;
- Implementação de experimentos para buscar a melhor solução para o problema. Dividiu-se a detecção das lesões vermelhas em duas etapas:
 - Detecção dos candidatos à lesão vermelha;
 - Detecção refinada das lesões vermelhas, com base nos candidatos encontrados na detecção anterior.
- Análise dos resultados com base nas medidas de sensibilidade, especificidade e outras.

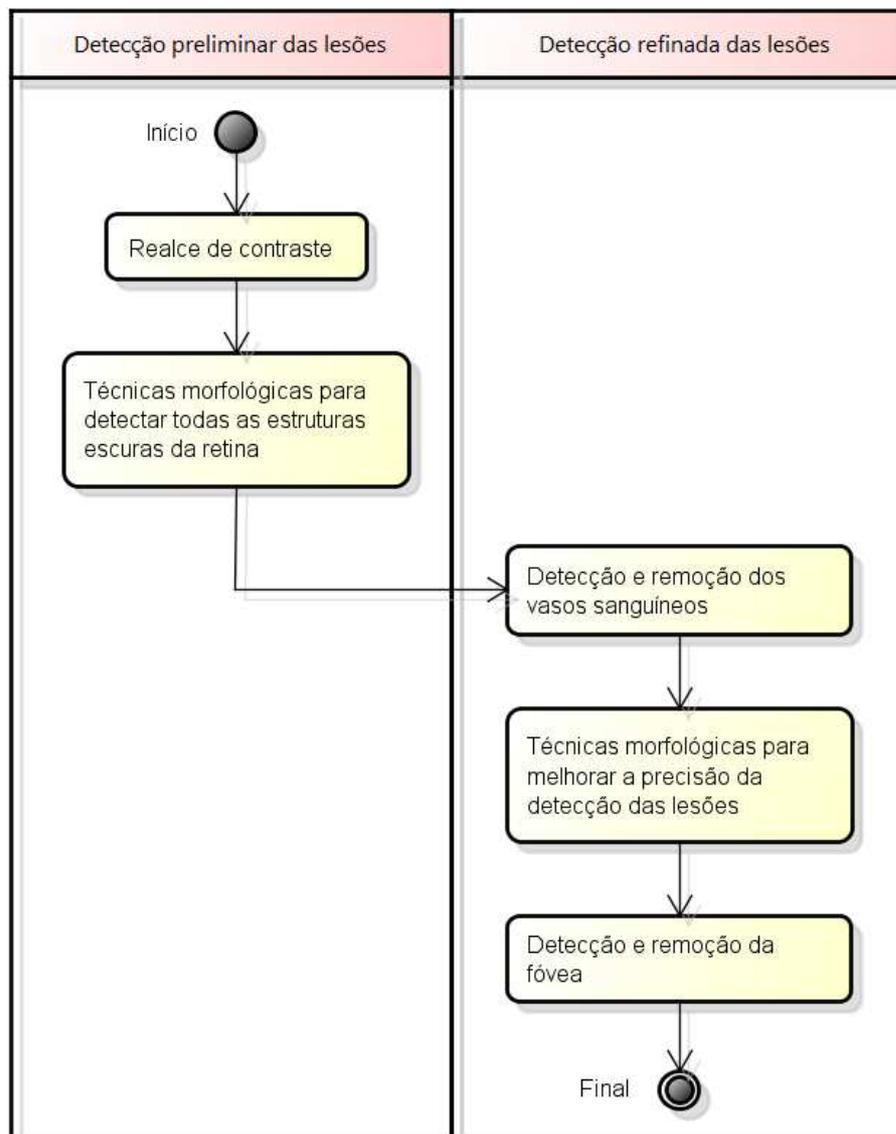
A Figura 1.6 ilustra o método de implementação dos experimentos na forma de diagrama de atividades, mostrando os dois passos importantes da detecção das lesões vermelhas: detecção preliminar das lesões e detecção refinada das lesões.

A fase de detecção preliminar tem por objetivo realizar uma detecção dos candidatos à lesão vermelha. Chamamos de detecção preliminar, pois nesta primeira fase outras estruturas presentes na retina, como a fóvea e os vasos sanguíneos, não são removidas da imagem. Dessa forma, essa fase é constituída de realce de contraste e técnicas morfológicas para que

apenas as estruturas escuras (isto é, lesões vermelhas, vasos sanguíneos e fóvea) sejam separadas do *background* da imagem.

Na fase de detecção refinada ocorre a remoção dos vasos sanguíneos e da região da fóvea, bem como a utilização de morfologia matemática para melhorar a precisão da detecção das lesões.

Figura 1.6 - Diagrama de atividades para o método de detecção desenvolvido



1.5 Organização do documento

Este documento está estruturado como segue:

Capítulo 2: Apresenta diversos trabalhos relacionados referentes à detecção de lesões vermelhas em imagens de fundo do olho, realizando um comparativo entre eles baseado nas medidas reportadas em cada trabalho.

Capítulo 3: Apresenta os fundamentos da morfologia matemática necessários para o entendimento do trabalho desenvolvido.

Capítulo 4: Descreve os materiais utilizados no trabalho, e o método desenvolvido para detectar automaticamente as lesões vermelhas.

Capítulo 5: Apresenta os resultados alcançados através do método elaborado, bem como as discussões sobre os mesmos.

Capítulo 6: Apresenta o fechamento do trabalho através das considerações finais e trabalhos futuros.

2 TRABALHOS RELACIONADOS

Neste capítulo são apresentados alguns trabalhos existentes sobre a detecção de lesões vermelhas em imagens da retina. Na literatura encontram-se diversos trabalhos que abordam esse assunto, porém os métodos propostos possuem formas diferentes de tratar o problema da detecção de lesões vermelhas. Sendo assim, o objetivo deste estudo é investigar os métodos utilizados pelos autores e verificar as características comuns entre os métodos de cada trabalho. Também, realizar uma análise baseada nas medidas de sensibilidade e especificidade que os autores utilizam para quantificar a precisão dos métodos propostos.

Para avaliar e quantificar os resultados obtidos, os autores utilizam imagens fornecidas por hospitais e marcadas por especialistas em oftalmologia, e também fazem uso dos diversos bancos de imagens públicos existentes, tais como DIARETDB0 (KAUPPI et al., 2006), DIARETDB1 (KAUPPI et al., 2007), DRIVE (STAAL et al., 2004), e STARE (HOOVER; GOLDBAUM, 2003). Em alguns casos, a origem das imagens não é mencionada.

A seção 2.1 apresenta nove trabalhos da literatura relacionados à detecção de lesões vermelhas. A seção 2.2 realiza um comparativo entre os resultados de cada trabalho. Por fim, a seção 2.3 faz o fechamento do capítulo.

2.1 Métodos propostos na literatura para detectar lesões vermelhas

Niemeijer et al. (2005) apresentam uma abordagem híbrida para o problema de detecção de lesões vermelhas em três etapas. Na primeira etapa, aplica-se correção de iluminação e também são removidas as lesões brancas presentes. Após a extração dos vasos sanguíneos da imagem, os objetos restantes são considerados como candidatos à lesão. Os objetos candidatos são extraídos na segunda etapa, utilizando dois métodos: classificação de pixels e morfologia matemática. Quando os candidatos de ambos os métodos são combinados, um maior número de candidatos à lesão é obtido. Na etapa final, a probabilidade de cada candidato representar uma lesão vermelha é estimada utilizando a classificação do método de K-vizinhos mais próximos (*KNN*) e um conjunto de características específicas. Para testar o sistema completo foi utilizado um conjunto de 100 imagens, onde 74 imagens foram obtidas através de um hospital, e as 26 imagens restantes foram retiradas de um programa de triagem de RD na Holanda. Essa abordagem alcançou uma sensibilidade de 100%, combinada com uma especificidade de 87%.

Badea et al. (2008) apresentam uma extensão do método do gradiente para a detecção das lesões vermelhas. O método consiste em quatro etapas. Na etapa de pré-processamento da imagem, é realizada a remoção de ruído, suavização e correção de iluminação. A segunda etapa detecta todos os objetos presentes na imagem utilizando o método *Expanding Gradient Method* (EGM). O resultado desse método é uma imagem em preto e branco que possui todos os elementos encontrados na imagem. Na terceira etapa os vasos sanguíneos são removidos, bem como o disco óptico e as lesões brancas, e o restante dos objetos são considerados como candidatos à lesão vermelha. A última etapa decide quais candidatos são lesões analisando o histograma da região de cada candidato. Os resultados preliminares desse estudo apontam um reconhecimento correto das lesões de 85% e 15.3% de falsos positivos, das 47 imagens testadas. Os autores não explicam de que local foram retiradas as imagens.

Balasubramanian et al. (2008) propõem um novo método para detectar automaticamente lesões vermelhas. Primeiramente, o canal verde da imagem é pré-processado, aplicando correção de sombra e melhorando o contraste. Após, a detecção dos candidatos à lesão é feita através do método chamado *Automatic Seed Generation* (ASG). Esse algoritmo separa os pixels que possuem a mesma intensidade que lesões vermelhas, incluindo os vasos sanguíneos, dos pixels restantes. O pixel será considerado um candidato à lesão se possuir a mesma intensidade que as lesões vermelhas e se for semelhante aos seus vizinhos. Cada conjunto desses pixels é definido como uma “semente”, ou seja, um candidato à lesão. Para detectar as lesões vermelhas foi utilizado um classificador híbrido denominado *Spatio Temporal Feature Map* (STFM). Também foi aplicado um novo recurso chamado variância elíptica para reduzir os falsos positivos. Utilizando 63 imagens marcadas por um especialista em oftalmologia, os autores reportaram uma sensibilidade de 87% e uma especificidade de 95.53%.

O método proposto por Garcia et al. (2008) pretende identificar lesões vermelhas da retina utilizando redes neurais *Multilayer Perceptron*. Primeiramente, normaliza-se o contraste e a luminosidade da imagem. O segundo passo é determinar os candidatos à lesão. Para isso, utiliza-se um método de regressão logística binária. Dessa forma, candidatos à lesão vermelha são separados do *background* da imagem. Esses candidatos à lesão são utilizados como entrada para um classificador denominado *Multilayer Perceptron* (MLP), que define o conjunto final de lesões vermelhas, utilizando um conjunto de 29 características extraídas de cada região. Nesse conjunto, estão algumas características que auxiliam o oftalmologista a distinguir visualmente as lesões vermelhas de outros objetos da retina. Utilizando 100

imagens retiradas de um instituto de oftalmobiologia, o método proposto obteve 100% de sensibilidade e 60% de especificidade.

No trabalho de Mariño et al. (2008) um novo algoritmo para a detecção de lesões vermelhas é proposto, que consiste em três fases. Na primeira fase, utilizando o canal verde da imagem, são aplicados filtros de correlação para obter um conjunto inicial de candidatos à lesão vermelha. Na segunda fase é feito um pré-processamento dos candidatos à lesão, utilizando um algoritmo de crescimento de regiões e, dessa forma, um conjunto mais preciso de candidatos é obtido. Na última fase, o conjunto de candidatos é filtrado por meio de três processos de filtragem, que: rejeitam regiões pouco circulares; removem candidatos que não satisfazem critérios de intensidade; e removem áreas que estão perto dos vasos sanguíneos. Utilizando um conjunto de 75 imagens obtidas em hospitais e marcadas por um especialista em oftalmologia, os resultados mostram que 70.7% das lesões detectadas foram corretamente detectadas, com uma sensibilidade de 78.5%.

Ravishankar et al. (2009) propõem um método automático para detectar retinopatia diabética em imagens de fundo de olho. Uma das etapas do processo de detecção da doença é verificar se a imagem contém microaneurismas ou hemorragias, que são as lesões vermelhas. Elas são tratadas como pequenas manchas escuras e sua identificação é feita através de preenchimento morfológico e limiarização sobre o canal verde da imagem. Após esse processo, os vasos sanguíneos são identificados através de operações de abertura e fechamento, e são removidos juntamente com os pixels que não satisfazem o modelo de cor. Por fim, a fóvea é detectada e removida, utilizando a localização do disco óptico e a curvatura dos vasos sanguíneos principais. Utilizando um conjunto de 516 imagens, o método proposto atingiu 95.1% de sensibilidade e 90.5% de especificidade. As imagens utilizadas no experimento foram obtidas de hospitais e bancos de imagens como DIARETDB0 (KAUPPI et al., 2006), DRIVE (STAAL et al., 2004) e STARE (HOOVER; GOLDBAUM, 2003).

Esmaeili et al. (2010) propõem um novo algoritmo baseado na transformada *curvelet* para separar as lesões vermelhas do resto da imagem. Para evitar que a fóvea seja considerada como uma lesão, um algoritmo de equalização de iluminação é apresentado, que é aplicado no canal verde da imagem. Após, é aplicada a transformada *curvelet* para que os pixels que façam parte dos vasos sanguíneos e das lesões vermelhas sejam separados do resto da imagem, como pixels candidatos. Essas lesões são separadas como regiões candidatas aplicando um limiar adequado. Por fim, a estrutura de vasos sanguíneos é extraída empregando uma técnica baseada em *curvelet*. Após a remoção dos vasos sanguíneos, os objetos restantes são considerados como lesões vermelhas. Experimentos realizados em 89

imagens do banco de imagens público DIARETDB1 (KAUPPI et al., 2007) mostram que foi atingida uma sensibilidade de 94% e uma especificidade de 87% na detecção de lesões vermelhas.

O artigo de Kande et al. (2010) apresenta uma abordagem eficiente para a detecção automática de lesões vermelhas nas imagens de fundo de olho, com base na classificação dos pixels e na morfologia matemática. Primeiramente, a imagem é pré-processada, utilizando informações de intensidade dos canais vermelho e verde. A etapa de pré-processamento modifica o histograma do canal verde utilizando o histograma do canal vermelho, obtendo assim uma nova imagem. Para detectar os candidatos à lesão, conceitos relacionados a filtros combinados e técnicas de limiarização local são utilizados. Para remover os vasos sanguíneos da imagem, são utilizadas transformações morfológicas. Por fim, os candidatos à lesão vermelha são classificados utilizando máquinas de vetores de suporte. O método foi testado em 89 imagens, onde atingiu 100% de sensibilidade e 91% de especificidade. Das 89 imagens utilizadas, 54 delas foram fornecidas por um hospital. As outras 35 imagens foram selecionadas randomicamente dos bancos de imagens STARE (HOOVER; GOLDBAUM, 2003), DIARETDB0 (KAUPPI et al., 2006) e DIARETDB1 (KAUPPI et al., 2007).

O método proposto por Jaafar et al. (2011) pretende localizar automaticamente lesões vermelhas utilizando técnicas morfológicas para segmentar os candidatos à lesões vermelhas e diferenciar lesões verdadeiras de lesões falsas utilizando um classificador baseado em regras. O método é dividido em três etapas. A fase de pré-processamento consiste na transformação do canal da imagem para verde e na correção da sombra. Na segunda etapa, um método que detecta vasos sanguíneos é apresentado para refinar os candidatos à lesão vermelha. Na terceira etapa ocorre a detecção das lesões vermelhas, onde é realizada uma segmentação dos candidatos à lesão e a extração dos vasos sanguíneos da imagem. Em um conjunto de 219 imagens retiradas de bancos de dados distintos, esse método detecta as lesões vermelhas com uma sensibilidade de 98.8% e uma especificidade de 86.2%. Das 219 imagens utilizadas, 89 fazem parte do DIARETDB1 (KAUPPI et al., 2007) e as 130 restantes são do DIARETDB0 (KAUPPI et al., 2006).

2.2 Comparativo entre trabalhos relacionados

A comparação dos trabalhos relacionados é realizada através das medidas de sensibilidade e especificidade alcançadas em cada um dos métodos.

É importante observar que este trabalho utiliza as medidas de sensibilidade e especificidade, além de outras, para realizar a quantificação do método desenvolvido (ver mais detalhes na Seção 5.1).

A Tabela 2.1 sumariza as medidas de sensibilidade e especificidade reportadas pelos autores em seus trabalhos, bem como as medidas encontradas neste trabalho através do método proposto.

Tabela 2.1 - Resultados obtidos para os métodos propostos na literatura

Autor(es)	Utiliza imagens públicas	Sensibilidade	Especificidade
Niemeijer et al. (2005)	Não	100%	87%
Badea et al. (2008)	Não descrito	Não descrito	Não descrito
Balasubramanian et al. (2008)	Não descrito	87%	95.53%
Garcia et al. (2008)	Não	100%	60%
Mariño et al. (2008)	Não	78.5%	Não descrito
Ravishankar et al. (2009)	Algumas: DIARETDB0, DRIVE e STARE	95.1%	90.5%
Esmaeili et al. (2010)	Sim: DIARETDB1	94%	87%
Kande et al. (2010)	Algumas: STARE, DIARETDB0 e DIARETDB1	100%	91%
Jaafar et al. (2011)	Sim: DIARETDB0 e DIARETDB1	98.8%	86.2%
Este trabalho	Sim: DIARETDB1	75.82%	93.49%

2.3 Conclusão

De forma geral, a literatura já oferece diversos métodos para detectar lesões vermelhas em imagens da retina. Parte desses trabalhos aplica conceitos de morfologia matemática em conjunto com outros métodos de processamento de imagem (classificação de pixels, por exemplo), obtendo um alto valor de sensibilidade. Porém, ainda é possível melhorar o processo de detecção de lesões vermelhas para obter um alto valor para as duas medidas, de sensibilidade e especificidade. Também se percebe que alguns trabalhos da literatura preocupam-se apenas em atingir altos valores de sensibilidade. A especificidade detecta o quão específico é o método desenvolvido, isto é, ela mostra a porcentagem de lesões vermelhas detectadas que, de fato, são lesões vermelhas na imagem. Um método que alcança alta sensibilidade, mas não obtém alta especificidade, significa que consegue detectar muitas estruturas na imagem. Dessa quantidade de objetos detectados, grande parte das lesões foi detectada (daí o alto valor na sensibilidade), mas também outras estruturas que não são lesões

foram detectadas como lesões (daí o valor médio na especificidade). É importante obter altos valores em ambas as medidas, pois Kauppi et al. (2007) afirmam que quanto maior a sensibilidade e a especificidade, melhor é o diagnóstico.

Outro fator importante é o conjunto de imagens utilizadas para testar os métodos. Muitos autores utilizam imagens não públicas (por exemplo, de hospitais). Como não são imagens acessíveis, isso impede a replicação dos métodos da literatura utilizando as mesmas imagens que os autores. Geralmente, imagens de hospital são delimitadas por apenas um especialista em oftalmologia. Pequenas lesões podem passar despercebidas quando o especialista realizar a marcação das imagens. Além disso, não é possível verificar certas características da imagem, como o contraste e a luminosidade, o número e tamanho das lesões vermelhas presentes, ou até mesmo se as imagens contêm outras anomalias, como lesões brancas. Ao utilizar um banco de imagens público, tem-se a chance de testar o método utilizando imagens que possuem diferenças de contraste e variado número de lesões presentes, tanto lesões vermelhas quanto lesões brancas.

Para realizar uma detecção mais precisa de lesões vermelhas, algumas técnicas podem ser aplicadas. Kande et al. (2010) afirmam que para realizar uma detecção eficiente das lesões vermelhas é desejável obter um alto contraste entre as lesões vermelhas e o fundo da retina, e ter um baixo contraste entre o fundo da retina e as lesões claras, resultando na redução de falsos positivos (FP). O tipo FP ocorre quando uma lesão que não está presente na imagem é detectada, ou seja, ocorre quando uma lesão anormal é detectada na imagem de fundo do olho quando, na realidade, não existe lesão (KAUPPI et al., 2007). Por sua vez, Jaafar et al. (2011) afirmam que a maioria dos falsos positivos detectados durante a escolha dos candidatos à lesão deve-se aos vasos sanguíneos.

O presente trabalho se fundamentará em métodos de reconstrução morfológica para resolver o problema da detecção de lesões vermelhas em imagens de fundo do olho. Em adição, o método será constituído por duas fases: detecção preliminar e detecção refinada das lesões vermelhas.

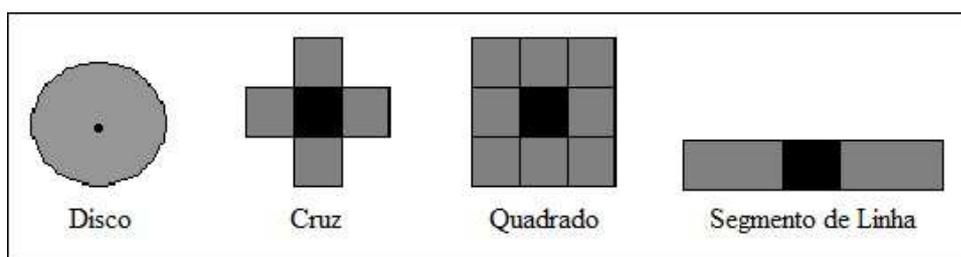
3 FUNDAMENTOS DE MORFOLOGIA MATEMÁTICA

Este trabalho se baseia nos conceitos de morfologia matemática. Operadores morfológicos foram utilizados nas duas fases de detecção das lesões: fase de detecção dos candidatos à lesão, e fase de detecção refinada das lesões. Dessa forma, o objetivo deste capítulo é apresentar uma visão geral dos operadores morfológicos utilizados neste trabalho. Esses operadores morfológicos foram utilizados tanto para imagens tons de cinza como para imagens binárias. Uma vez que os operadores mudam sua definição de acordo com o tipo de imagem (tons de cinza ou binária), aqui serão apresentados os operadores morfológicos utilizados em imagens tons de cinza, bem como os operadores utilizados em imagens binárias.

A morfologia matemática foi desenvolvida na década de 60 pelos pesquisadores Georges Matheron e Jean Serra, da *École Supérieure des Mines de Paris*, em Fontainebleau, França (FACON, 1996). Basicamente a morfologia matemática consiste em extrair de uma imagem desconhecida informações sobre sua geometria e topologia, pela transformação através de outro conjunto bem definido, denominado elemento estruturante (MARQUES FILHO; VIEIRA NETO, 1999). A forma do elemento estruturante geralmente é escolhida de acordo com algum conhecimento sobre a geometria das estruturas da imagem (SOILLE, 2003). Ishikawa (2008) afirma que a grande potencialidade da morfologia matemática é o elemento estruturante e, dessa forma, deve-se fazer uma escolha adequada para obter bons resultados. Ishikawa (2008) ainda resume o funcionamento do elemento estruturante: ele percorre toda a imagem, pixel a pixel, realizando algumas transformações na vizinhança do pixel que está sendo analisado e atribuindo o resultado ao pixel correspondente da nova imagem.

A Figura 3.1 apresenta os elementos estruturantes presentes na biblioteca de morfologia matemática MMORPH (MMORPH, 2008).

Figura 3.1 - Elementos estruturantes presentes no MMORPH



Fonte: adaptado de Ishikawa (2008).

Além da forma, o elemento estruturante também possui outra característica, que é o tamanho. Neste trabalho, o tamanho do elemento estruturante utilizado nos experimentos é chamado de *raio*.

As duas operações básicas da morfologia matemática são a dilatação e a erosão. Esses dois operadores constituem a base para os demais operadores morfológicos. Primeiramente, serão descritas as operações da morfologia matemática para imagens tons de cinza. Posteriormente, serão apresentados os operadores morfológicos para imagens binárias.

A dilatação tons de cinza de uma imagem f por um elemento estruturante B em um determinado pixel x da imagem é o valor máximo da imagem na vizinhança definida pelo elemento estruturante quando sua origem está em x , e é definida de acordo com a Equação 3.1 (SOILLE, 2003). A dilatação resulta no aumento das partes de maior intensidade da imagem.

$$\delta^{(B)}(f)(x) = \max_{b \in B} f(x + b) \quad (3.1)$$

A erosão tons de cinza de uma imagem f por um elemento estruturante B em um determinado pixel x da imagem é o valor mínimo da imagem na vizinhança definida pelo elemento estruturante quando sua origem está em x , e é definida de acordo com a Equação 3.2 (SOILLE, 2003). A erosão resulta no aumento das partes de menor intensidade da imagem.

$$\varepsilon^{(B)}(f)(x) = \min_{b \in B} f(x + b) \quad (3.2)$$

Agora, é possível definir os operadores de abertura e fechamento morfológico tons de cinza.

A operação de abertura tons de cinza de uma imagem f por um elemento estruturante B é denotada como $\gamma^{(B)}f$ e é definida como a erosão de f pelo elemento estruturante B , seguida pela dilatação do resultado da erosão pelo mesmo elemento estruturante, como pode ser vista na Equação 3.3 (SOILLE, 2003). Em outras palavras, a abertura é uma erosão seguida de uma dilatação, utilizando um mesmo elemento estruturante.

$$\gamma^{(B)}f = \delta^{(B)}(\varepsilon^{(B)}(f)) \quad (3.3)$$

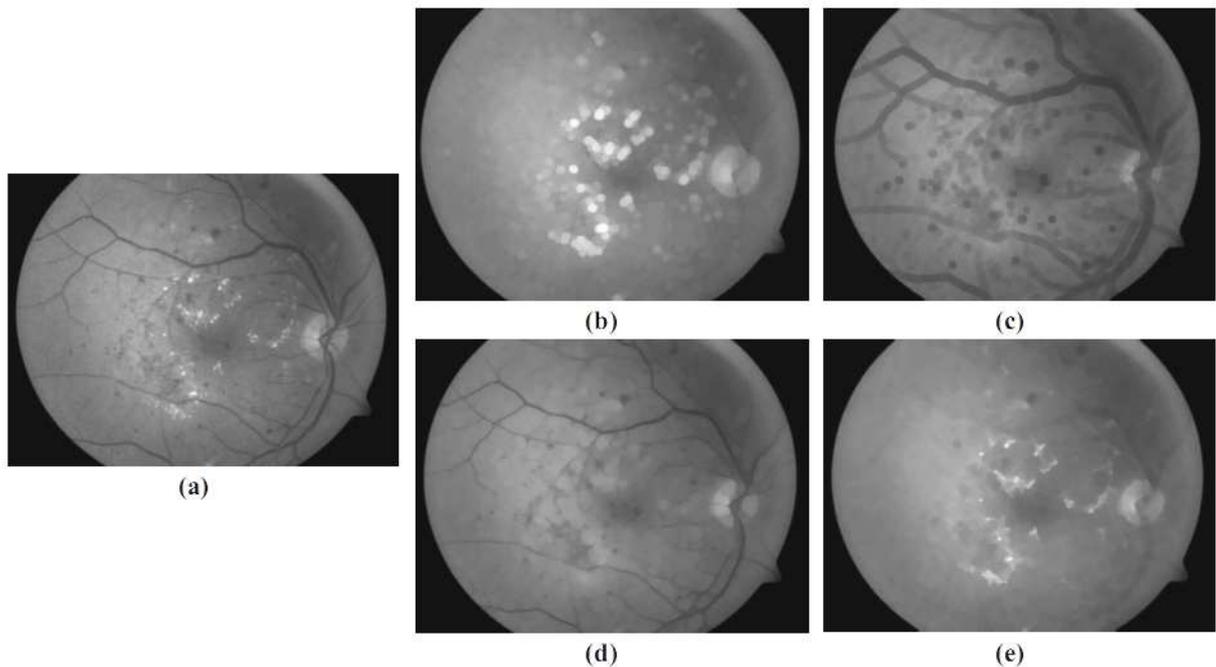
Já o fechamento tons de cinza é a operação inversa da abertura, pois primeiro realiza a dilatação e, em seguida, a erosão. Assim, o fechamento de uma imagem f por um elemento

estruturante B é denotado como $\phi^{(B)}f$, sendo definido como a dilatação de f pelo elemento estruturante B , seguida pela erosão do resultado da dilatação pelo mesmo elemento estruturante, como mostra a Equação 3.4 (SOILLE, 2003).

$$\phi^{(B)}f = \varepsilon^{(B)}(\delta^{(B)}(f)) \quad (3.4)$$

A Figura 3.2 ilustra os resultados das operações apresentadas anteriormente, em uma imagem da retina, onde a Figura 3.2 (a) mostra a imagem original em tons de cinza, a Figura 3.2 (b) apresenta o resultado da operação de dilatação, a Figura 3.2 (c) mostra o resultado da operação de erosão, a Figura 3.2 (d) apresenta o resultado da abertura, e a Figura 3.2 (e) apresenta o resultado do fechamento.

Figura 3.2 – Operações tons de cinza de dilatação, erosão, abertura e fechamento



(a) Imagem original em tons de cinza; (b) Resultado da operação de dilatação; (c) Resultado da operação de erosão; (d) Resultado da operação de abertura; (e) Resultado da operação de fechamento.

Os operadores morfológicos apresentados até o momento envolvem combinações de uma imagem de entrada com elementos estruturantes específicos. Porém, a ideia dos operadores geodésicos é utilizar duas imagens de entrada, denominadas imagem marca e imagem máscara. Para definir os operadores geodésicos, considere uma imagem marca f e uma imagem máscara g . Também assumo que as operações de dilatação e erosão básicas são denotadas por δ e ε , respectivamente. A dilatação geodésica de ordem n denotada por

$\delta_g^{(n)}(f)$, onde $f \leq g$, e a erosão geodésica de ordem n denotada por $\varepsilon_g^{(n)}(f)$, onde $f \geq g$, são mostradas na Equação 3.5 e Equação 3.6, respectivamente (JÄHNE; HAUBECKER; GEIBLER, 1999).

$$\delta_g^{(n)}(f) = \delta_g^{(1)}\left(\delta_g^{(n-1)}(f)\right), \text{ com } \delta_g^{(1)}(f) = \delta^{(1)}(f) \wedge g, \quad (3.5)$$

$$\varepsilon_g^{(n)}(f) = \varepsilon_g^{(1)}\left(\varepsilon_g^{(n-1)}(f)\right), \text{ com } \varepsilon_g^{(1)}(f) = \varepsilon^{(1)}(f) \vee g, \quad (3.6)$$

onde n representa o número de dilatações ou erosões sucessivas de f em relação a g , \wedge e \vee representam os operadores de mínimo e máximo, $\delta^{(1)}$ é a dilatação elementar e $\varepsilon^{(1)}$ é a erosão elementar. Resumidamente, a ideia dos operadores geodésicos é que a imagem máscara limite o resultado da transformação.

Dilatações e erosões geodésicas não são muito utilizadas na prática, porém, se forem realizadas sucessivamente até a estabilidade, elas definem os algoritmos de reconstrução morfológica. Assim, a reconstrução por dilatação, denotada por $\mathcal{R}_g(f)$, é definida na Equação 3.7, e a reconstrução por erosão, denotada por $\mathcal{R}_g^*(f)$, é definida na Equação 3.8 (JÄHNE; HAUBECKER; GEIBLER, 1999).

$$\mathcal{R}_g(f) = \delta_g^{(i)}(f), \text{ onde } i \text{ é tal que } \delta_g^{(i)}(f) = \delta_g^{(i+1)}(f) \quad (3.7)$$

$$\mathcal{R}_g^*(f) = \varepsilon_g^{(i)}(f), \text{ onde } i \text{ é tal que } \varepsilon_g^{(i)}(f) = \varepsilon_g^{(i+1)}(f) \quad (3.8)$$

A partir dos operadores de reconstrução apresentados anteriormente, é possível definir ainda os operadores *RMAX* e *RMIN*, e também as transformadas *H-maxima* e *H-minima*.

O máximo regional de uma imagem f , denotado por *RMAX*, é um conjunto de pixels conectados de valor t que são cercados por pixels de valor estritamente menor que t . Por outro lado, o mínimo regional de uma imagem f , denotado por *RMIN*, é um conjunto de pixels conectados de valor t que são cercados por pixels de valor estritamente maior que t . Os máximos e mínimos regionais podem ser encontrados de acordo com a Equação 3.9 e Equação 3.10, respectivamente (JÄHNE; HAUBECKER; GEIBLER, 1999).

$$RMAX(f) = f + 1 - \mathcal{R}_{f+1}(f) \quad (3.9)$$

$$RMIN(f) = \mathcal{R}_f^*(f + 1) - f \quad (3.10)$$

Por fim, as transformadas *H-maxima* e *H-minima* permitem filtrar os extremos da imagem f utilizando um critério de contraste. O filtro *H-maxima* remove todos os picos conectados (ou seja, as regiões de alto contraste) que contém um contraste menor que um limiar h , sendo definido através da Equação 3.11. Da mesma forma, o filtro *H-minima*, definido na Equação 3.12, remove todos os vales conectados (ou seja, as regiões de baixo contraste) cujo contraste é menor que o parâmetro h (SOILLE, 2003).

$$Hmax_h(f) = \mathcal{R}_f(f - h) \quad (3.11)$$

$$Hmin_h(f) = \mathcal{R}_f^*(f + h) \quad (3.12)$$

Todos os operadores morfológicos apresentados até o momento são aplicados em imagens tons de cinza. Porém, em algumas etapas do método desenvolvido neste trabalho, as imagens resultantes são binárias. Dessa forma, agora serão apresentados os operadores morfológicos para imagens binárias necessários para o entendimento do método de detecção de lesões vermelhas desenvolvido.

A dilatação binária de um conjunto X por um elemento estruturante B é denotada por $\delta^{(B)}(X)$ e é definida como a posição dos pontos x tal que B atinge X quando sua origem coincide com x , como mostra a Equação 3.13 (SOILLE, 2003). Em resumo, a dilatação “engorda” a imagem binária.

$$\delta^{(B)}(X) = \{x | B_x \cap X \neq \emptyset\} \quad (3.13)$$

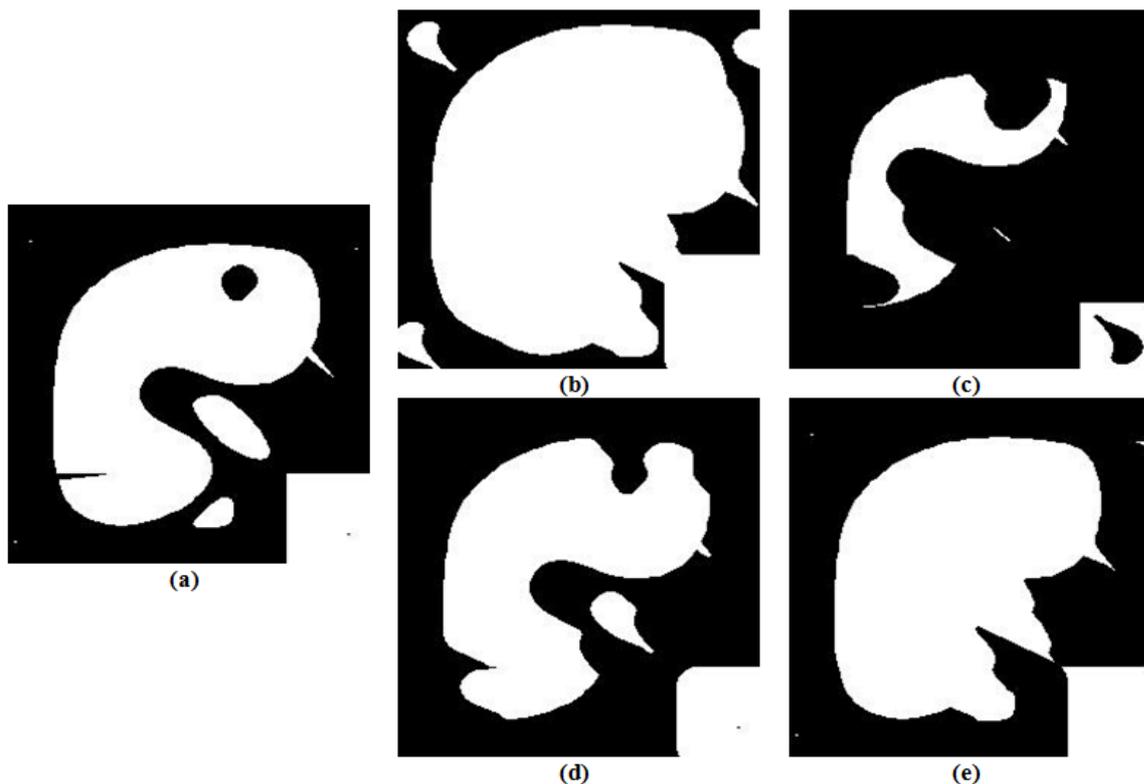
A erosão binária de um conjunto X por um elemento estruturante B é denotada por $\varepsilon^{(B)}(X)$ e define-se como a posição dos pontos x tal que B está incluído em X , quando sua origem é colocada sobre x , conforme a Equação 3.14 (SOILLE, 2003). A erosão resulta no “emagrecimento” da imagem binária.

$$\varepsilon^{(B)}(X) = \{x | B_x \subseteq X\} \quad (3.14)$$

As operações de abertura e fechamento em imagens binárias funcionam da mesma forma que a abertura e fechamento tons de cinza, porém utilizando dilatações e erosões binárias em sua composição. Isto é, a abertura binária é o resultado da erosão binária seguida pela dilatação binária, utilizando um mesmo elemento estruturante. Por outro lado, o fechamento binário resulta da dilatação binária seguida pela erosão binária, usando um mesmo elemento estruturante.

É possível visualizar na Figura 3.3 os resultados das operações apresentadas anteriormente, em uma imagem binária, onde a Figura 3.3 (a) mostra a imagem original binária, a Figura 3.3 (b) apresenta o resultado da operação de dilatação, a Figura 3.3 (c) mostra o resultado da operação de erosão, a Figura 3.3 (d) apresenta o resultado da abertura, e a Figura 3.3 (e) apresenta o resultado do fechamento.

Figura 3.3 - Operações binárias de dilatação, erosão, abertura e fechamento



(a) Imagem original binária; (b) Resultado da operação de dilatação; (c) Resultado da operação de erosão; (d) Resultado da operação de abertura; (e) Resultado da operação de fechamento.

Fonte: adaptado de MMORPH (2008).

Dessa forma, os conceitos apresentados neste capítulo contribuem para o entendimento do método desenvolvido que é apresentado no capítulo seguinte.

4 MATERIAIS E MÉTODOS PARA A DETECÇÃO DE LESÕES

Neste capítulo serão apresentados os materiais utilizados na realização deste trabalho, bem como o método desenvolvido para detectar automaticamente lesões vermelhas. Como descrito anteriormente, o método elaborado neste trabalho é dividido em duas etapas. A primeira etapa realiza uma detecção preliminar das lesões vermelhas, isto é, uma detecção dos candidatos à lesão. Na segunda etapa é realizada a detecção refinada das lesões, com base nos candidatos detectados anteriormente.

A seção 4.1 descreve os materiais utilizados para testar o método. A seção 4.2 apresenta o método realizado para a detecção preliminar das lesões. A seção 4.3 descreve o método realizado para a detecção refinada das lesões, ou seja, a detecção final das lesões vermelhas. Por fim, a seção 4.4 apresenta o fechamento do capítulo.

4.1 Materiais

O objetivo desta seção é apresentar os materiais utilizados para testar e validar o método desenvolvido para a detecção automática de lesões vermelhas.

Este trabalho baseia-se nos conceitos de morfologia matemática. Os passos descritos neste capítulo foram implementados em MATLAB (MathWorks, 1994). Em adição, utilizou-se a implementação dos operadores morfológicos presentes na biblioteca MMORPH (2008) (DOUGHERTY; LOTUFO, 2003).

As imagens utilizadas neste trabalho compõem o banco de imagens da retina DIARETDB1 e estão disponíveis livremente na internet para download (KAUPPI et al., 2007).

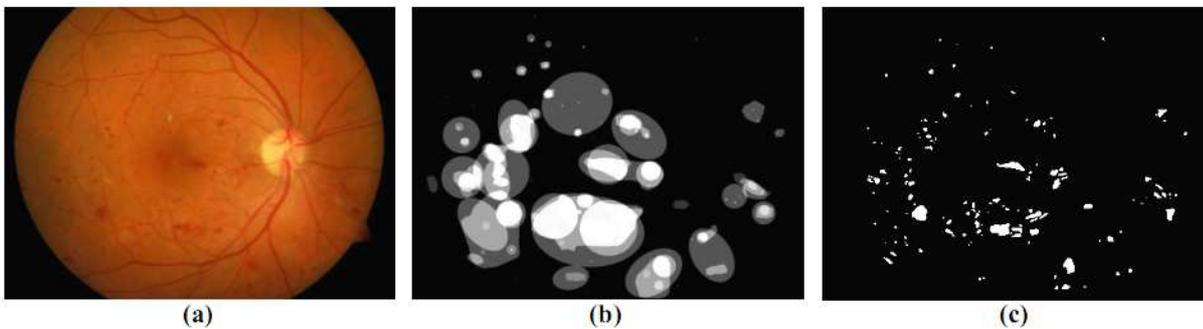
O DIARETDB1 tem sido muito utilizado em trabalhos que realizam análise de imagens da retina como, por exemplo, nos artigos de Akram et al. (2008) e de Tariq et al. (2010), que apresentam um método para realizar a segmentação de ruído em imagens da retina, e também nos estudos de Fang et al. (2010) e Salazar-Gonzalez et al. (2011), que propõem métodos para segmentar exsudatos duros e o disco óptico, respectivamente.

O DIARETDB1 é um banco de imagens público finlandês que contém 89 imagens coloridas (RGB) de fundo do olho, de 1500 x 1152 pixels. De acordo com Kauppi et al. (2007), as imagens possuem diferenças como, por exemplo, a intensidade do flash. Das 89

imagens da retina, 84 imagens contêm sinais de RDNP, tais como microaneurismas, exsudatos e hemorragias, e 5 imagens não possuem sinais de RD (KAUPPI et al., 2007).

Todas as imagens do DIARETDB1 foram marcadas manualmente por quatro profissionais em oftalmologia utilizando um software de anotação desenvolvido utilizando a ferramenta de computação científica MATLAB. De acordo com KAUPPI et al. (2007), esses especialistas foram orientados a marcar áreas que contivessem microaneurismas, hemorragias e exsudatos. Como o processo de coleta causou diferenças significativas entre os médicos especialistas, foi feita uma união das marcações, obtendo-se assim o *ground truth* do banco de imagens. No entanto, as marcações não foram realizadas de forma precisa, pois os especialistas marcaram as áreas onde havia um conjunto de lesões, e não cada lesão em separado. Dessa forma, utilizando como base esse *ground truth* disponibilizado pelo banco de imagens, realizou-se a marcação manual de cada lesão vermelha, com o auxílio de um editor de imagens. A Figura 4.1 ilustra essas marcações, onde a Figura 4.1 (a) mostra a imagem original de fundo do olho, a Figura 4.1 (b) mostra o *ground truth* disponibilizado pelo banco de imagens, e a Figura 4.1 (c) mostra a marcação manual realizada com base no *ground truth*.

Figura 4.1 - *Ground truth* das imagens do DIARETDB1



(a) Imagem original com as lesões vermelhas (KAUPPI et al., 2007); (b) Marcação das lesões vermelhas feita por especialistas (KAUPPI et al., 2007); (c) Marcação manual das lesões vermelhas realizada.

Algumas considerações devem ser feitas em relação a essa marcação manual realizada. Como dito anteriormente, o *ground truth* disponibilizado pelo banco de imagens serviu como base para a marcação precisa das lesões vermelhas. Porém, algumas dessas marcações realizadas por oftalmologistas não foram consideradas quando a marcação manual foi feita. Isso porque, em alguns casos, o objeto que foi identificado como sendo uma lesão vermelha era muito pequeno, e foi delimitado por apenas um ou dois especialistas. Dessa forma, analisando cada marcação desse tipo, optou-se por não incluí-la no *ground truth* da

imagem, visto que ela não foi identificada por mais da metade dos especialistas. Ao todo, 34 imagens sofreram essa modificação.

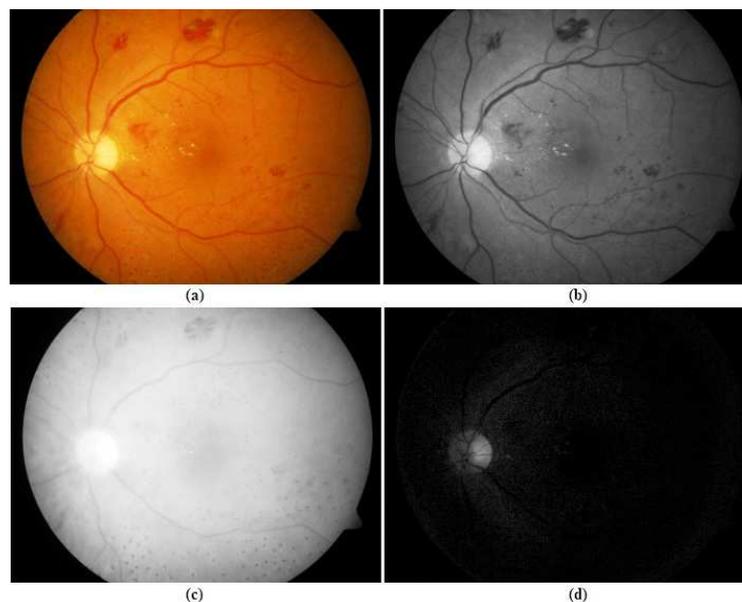
Considere como imagem com lesão aquela que contém microaneurismas e/ou hemorragias, e considere como imagem sem lesão aquela que não contém nenhuma dessas estruturas. O banco de imagens possui 83 imagens com lesão, e 6 imagens sem lesão. No entanto, considerando que foi realizada a correção do *ground truth* em certas marcações, esses números mudaram: 53 imagens com lesão, e 36 imagens sem lesão. Isso ocorreu porque 30 imagens continham até 5 lesões pequenas que foram delimitadas por um ou dois especialistas, ocorrendo o caso explicado anteriormente.

O Apêndice A apresenta uma tabela com a listagem das imagens do DIARETDB1 que tiveram seu *ground truth* modificado, bem como o número de marcações que não foram consideradas em cada imagem, e o número de especialistas que realizaram essas marcações.

4.2 Método para a detecção preliminar das lesões vermelhas

Os operadores morfológicos foram aplicados no canal verde da imagem original RGB. Foi utilizada a imagem no canal verde, pois as imagens da retina neste canal geralmente possuem melhor contraste (HOOVER; KOUZNETSOVA; GOLDBAUM, 2000). A diferença entre os três canais de uma imagem pode ser vista na Figura 4.2.

Figura 4.2 - Diferença entre os três canais de uma imagem



A mesma imagem vista em diferentes canais, onde (a) é a imagem original RGB, (b) é a imagem no canal verde, (c) é a imagem no canal vermelho e (d) é a imagem no canal azul.

Dessa forma, primeiramente aplicou-se no canal verde f_g da imagem original uma técnica de realce de contraste denominada *Contrast Limited Adaptive Histogram Equalization* (CLAHE) (ZUIDERVELD, 1994). O filtro CLAHE tem produzido bons resultados em imagens médicas. Seu funcionamento é da seguinte forma: primeiramente, a imagem é dividida em várias regiões de tamanhos iguais (denominada “*tiles*”). Em seguida, o histograma de cada região é calculado. Após, com base no limite de expansão desejado para o contraste, um limite para os histogramas é definido (denominado “*clip limit*”). Por fim, cada histograma é redistribuído de tal forma que sua altura não ultrapasse esse limite (KURT et al., 2012).

Com isso, uma nova imagem f_1 é obtida, como mostra a Equação 4.1. Nos experimentos, utilizou-se um limite de corte de 0.2, e a imagem foi dividida em 10 x 10 regiões.

$$f_1 = \text{CLAHE}(f_g) \quad (4.1)$$

Após, na imagem f_1 é aplicado o método proposto por Walter et al. (2002) que remove variações do *background* e melhora o contraste. Essa técnica utiliza filtros sequenciais alternados (FSA) baseados em aberturas e fechamentos morfológicos para estimar o *background* f_2 da imagem f_1 , de acordo com a Equação 4.2.

$$f_2 = \left(\left(\left((f_1 \phi B) \gamma B \right) \dots \phi nB \right) \gamma nB \right), \quad (4.2)$$

onde B é um elemento estruturante em forma de disco com um raio de valor 8 e n é o número de iterações ($n = 2$ em nossos experimentos) na qual a combinação sequencial de abertura e fechamento é aplicada. Em seguida, uma nova imagem f_3 sem variações de *background* é obtida, de acordo com a Equação 4.3.

$$f_3 = f_2 - f_1 \quad (4.3)$$

É possível identificar regiões de baixo contraste na imagem f_1 (ou seja, áreas que podem ser associadas a lesões vermelhas) utilizando a reconstrução por dilatação em tons de cinza, como mostra a Equação 4.4. Para isso, a imagem marca sofreu uma erosão com um elemento estruturante em forma de disco com raio de valor 10.

$$f_4 = \mathcal{R}_{f_1} \left(\varepsilon^{(B)}(f_1) \right), \quad (4.4)$$

onde f_1 é a imagem máscara e $\varepsilon^{(B)}(f_1)$ é a imagem marca. Em adição, para realizar a reconstrução por dilatação, foi utilizado um elemento estruturante em forma de disco com um raio de valor 5.

Depois disso, a fim de nivelar mais essas áreas associadas a lesões vermelhas, são removidas as regiões de alta intensidade aplicando uma reconstrução por erosão em tons de cinza, como pode ser visto na Equação 4.5. Nesse caso, a imagem marca sofreu uma dilatação com um elemento estruturante em forma de disco de valor 7.

$$f_5 = \mathcal{R}_{f_4}^* \left(\delta^{(B)}(f_4) \right), \quad (4.5)$$

onde f_4 e $\delta^{(B)}(f_4)$ são a imagem máscara e a imagem marca, respectivamente. Para realizar essa reconstrução por erosão, utilizou-se um elemento estruturante em forma de disco com um raio de valor 10.

Após, a diferença entre as imagens f_5 e f_1 é calculada, como é mostrada na Equação 4.6. A saída dessa operação é uma imagem em tons de cinza onde as estruturas escuras da retina, como vasos sanguíneos e lesões vermelhas são realçadas.

$$f_6 = f_5 - f_1 \quad (4.6)$$

Agora, a diferença entre as transformadas *H-minima* e *H-maxima* da imagem f_6 é computada de acordo com a Equação 4.7. A saída da transformada *H-minima* é uma imagem onde as estruturas da retina como vasos sanguíneos e lesões vermelhas são removidas. Já a saída da transformada *H-maxima* é uma imagem onde os picos da imagem, isto é, as regiões de alto contraste, são removidas. Esta etapa será importante futuramente para detectar as lesões vermelhas sem utilizar técnicas de limiarização.

$$f_7 = \left(Hmin_h(f_6) - Hmax_h(f_6) \right)^c \quad (4.7)$$

onde h é o valor do limiar utilizado ($h = 2$ em nossos experimentos) e c representa o complemento da imagem.

Após essa etapa, a imagem f_8 tem por objetivo nivelar as regiões candidatas à lesão vermelha, através da utilização de fechamento morfológico, ϕ , seguido por abertura morfológica, γ , como mostra a Equação 4.8. Essa sequência de operadores pode ser definida como um filtro ordenado *close-open* (JÄHNE; HAUBECKER; GEIBLER, 1999).

$$f_8 = \gamma^{(B)} \left(\phi^{(B)}(f_7) \right), \quad (4.8)$$

onde B é o elemento estruturante utilizado (nesse caso, ambos os elementos estruturantes utilizados são na forma de cruz, com raio de valor 1).

A fim de melhorar a precisão da detecção das lesões, aplicou-se o método Toggle de realce de contraste morfológico (DOUGHERTY; LOTUFO, 2003). Conforme descrito na Equação 4.9, esse método realiza a operação de erosão e a dilatação em tons de cinza. Para isso, foi utilizado um elemento estruturante em forma de cruz, com raio de valor 3.

$$f_9 = \begin{cases} \varepsilon^{(B)}(f_8), & \text{se } f_{8(x,y)} - \varepsilon^{(B)}(f_8) \geq \delta^{(B)}(f_8) - f_{8(x,y)} \\ \delta^{(B)}(f_8), & \text{se } f_{8(x,y)} - \varepsilon^{(B)}(f_8) < \delta^{(B)}(f_8) - f_{8(x,y)} \end{cases} \quad (4.9)$$

Em adição, a imagem f_9 também sofreu as operações de fechamento de buracos (*closing-the-holes*), além de uma dilatação utilizando um elemento estruturante em forma de cruz, com raio de valor 2. Esses “buracos” são todos os componentes de mínimos regionais que não estão conectados à borda da imagem (Soille, 2003).

A operação de fechamento de buracos, definida pela Equação 4.10, realiza uma reconstrução por erosão utilizando uma imagem f como máscara, e uma imagem marca f_m , que é definida como o valor máximo de imagem, exceto nas bordas, onde os valores da imagem original são mantidos (Soille, 2003).

$$FILL(f) = \mathcal{R}_f^*(f_m) \quad (4.10)$$

Finalmente, com o objetivo de detectar as regiões candidatas à lesão vermelha, foi empregado o operador *RMAX*, que detecta os pixels dos máximos regionais. Esse operador retorna uma imagem binária a partir de uma imagem tons de cinza, sem utilizar limiarização, o que o torna um operador adaptativo. Se um conjunto de pixels conectados da imagem f_9 tiver um valor de intensidade maior que seus pixels vizinhos, então seu valor é modificado

para “1”, senão seu valor é zero. A imagem resultante da operação de máximos regionais pode ser encontrada conforme a Equação 4.11.

$$f_{10} = RMAX(f_9) = f_9 + 1 - \mathcal{R}_{f_9+1}(f_9) \quad (4.11)$$

A fim de melhorar a precisão do método de detecção dos candidatos à lesão, foi necessário remover o fundo da imagem que não faz parte da retina. Dessa forma, aplicou-se uma máscara de fundo disponibilizada pelo banco de imagens DIARETDB1 (KAUPPI et al., 2007). Considere a máscara de fundo e a imagem f_{10} , na posição (x, y) da imagem, como $mask_{(x,y)}$ e $f_{10(x,y)}$, respectivamente. A Equação 4.12 descreve o processo de aplicação da máscara na imagem f_{10} .

$$f_{10(x,y)} = \begin{cases} 0, & \text{se } mask_{(x,y)} = 0 \\ f_{10(x,y)}, & \text{caso contrário} \end{cases} \quad (4.12)$$

O Algoritmo 1 mostra com detalhes os passos realizados na primeira fase de detecção.

Algoritmo 1: Pseudocódigo da primeira fase de detecção de lesões vermelhas

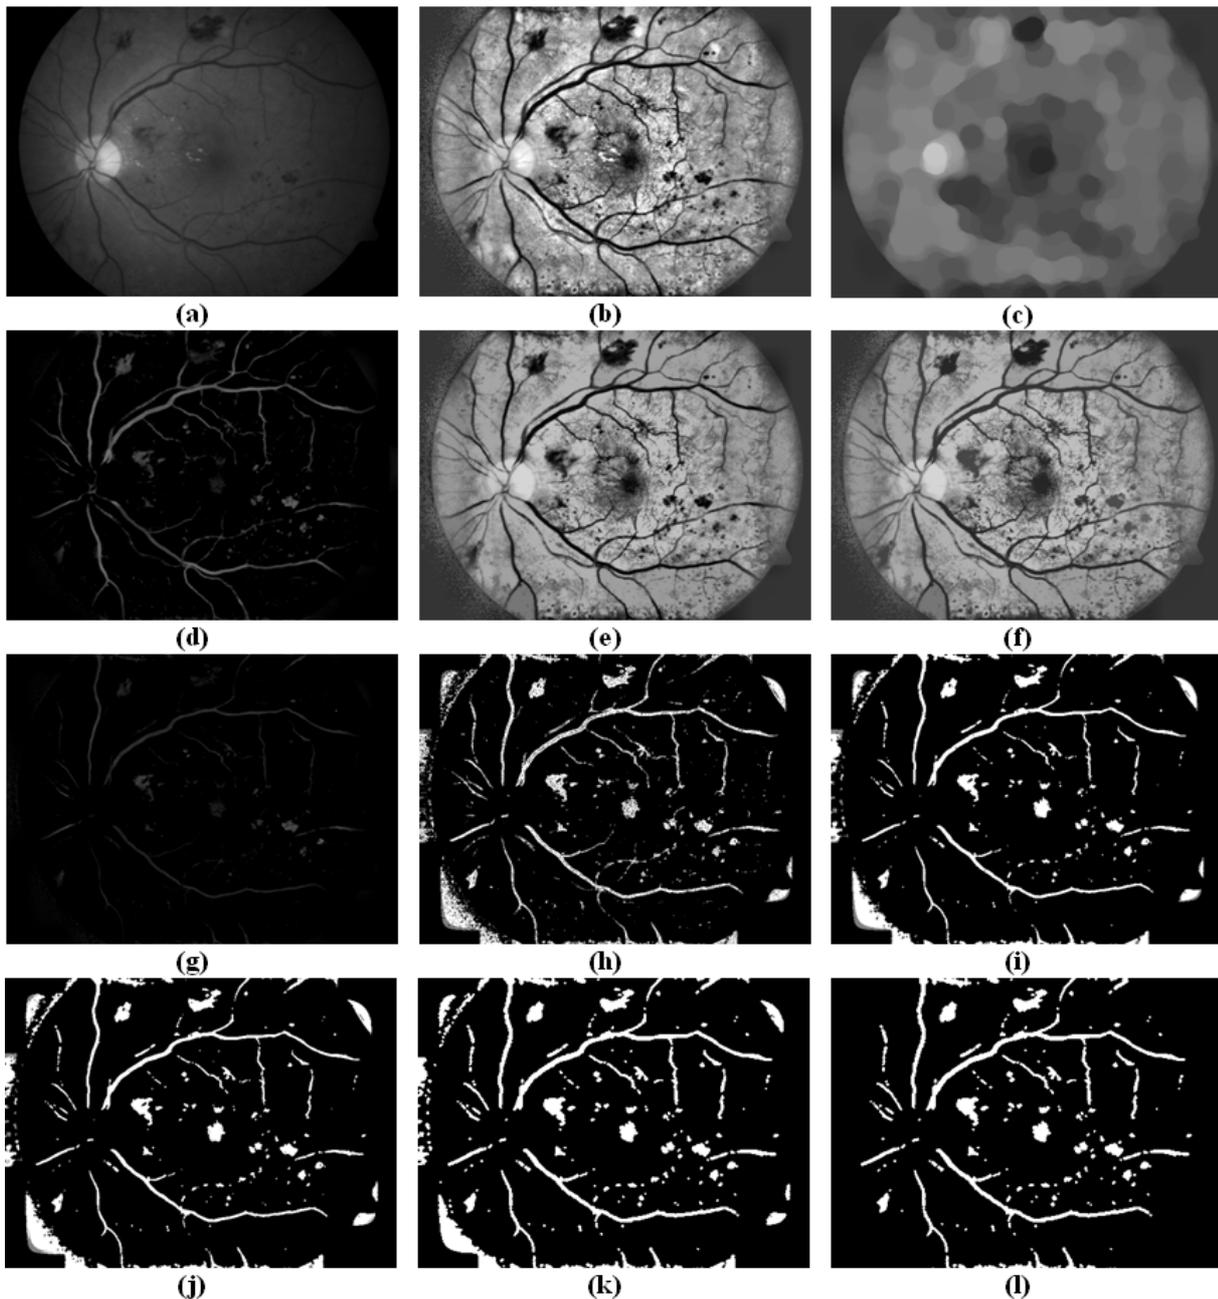
Entrada: imagem colorida de fundo do olho (RGB).

Saída: imagem binária com a detecção dos candidatos à lesão vermelha (f_{10}).

- 1 $f_g =$ seleciona apenas o componente verde da imagem colorida;
 - 2 $f_1 = CLAHE(f_g)$;
 - 3 $f_2 = \left(\left(\left((f_1 \phi B) \gamma B \right) \dots \phi nB \right) \gamma nB \right)$;
 - 4 $f_3 = f_2 - f_1$;
 - 5 $f_4 = \mathcal{R}_{f_1} \left(\varepsilon^{(B)}(f_1) \right)$;
 - 6 $f_5 = \mathcal{R}_{f_1}^* \left(\delta^{(B)}(f_4) \right)$;
 - 7 $f_6 = f_5 - f_1$;
 - 8 $f_7 = (Hmin_h(f_6) - Hmax_h(f_6))^c$;
 - 9 $f_8 = \gamma^{(B)} \left(\phi^{(B)}(f_7) \right)$;
 - 10 $f_9 = \begin{cases} \varepsilon^{(B)}(f_8), & \text{se } f_{8(x,y)} - \varepsilon^{(B)}(f_8) \geq \delta^{(B)}(f_8) - f_{8(x,y)} ; \\ \delta^{(B)}(f_8), & \text{se } f_{8(x,y)} - \varepsilon^{(B)}(f_8) < \delta^{(B)}(f_8) - f_{8(x,y)} \end{cases}$;
 - 11 $f_9 = \delta^{(B)}(FILL(f_9))$;
 - 12 $f_{10} = RMAX(f_9) = f_9 + 1 - \mathcal{R}_{f_9+1}(f_9)$;
 - 13 $f_{10(x,y)} = \begin{cases} 0, & \text{se } mask_{(x,y)} = 0 \\ f_{10(x,y)}, & \text{caso contrário} \end{cases}$.
-

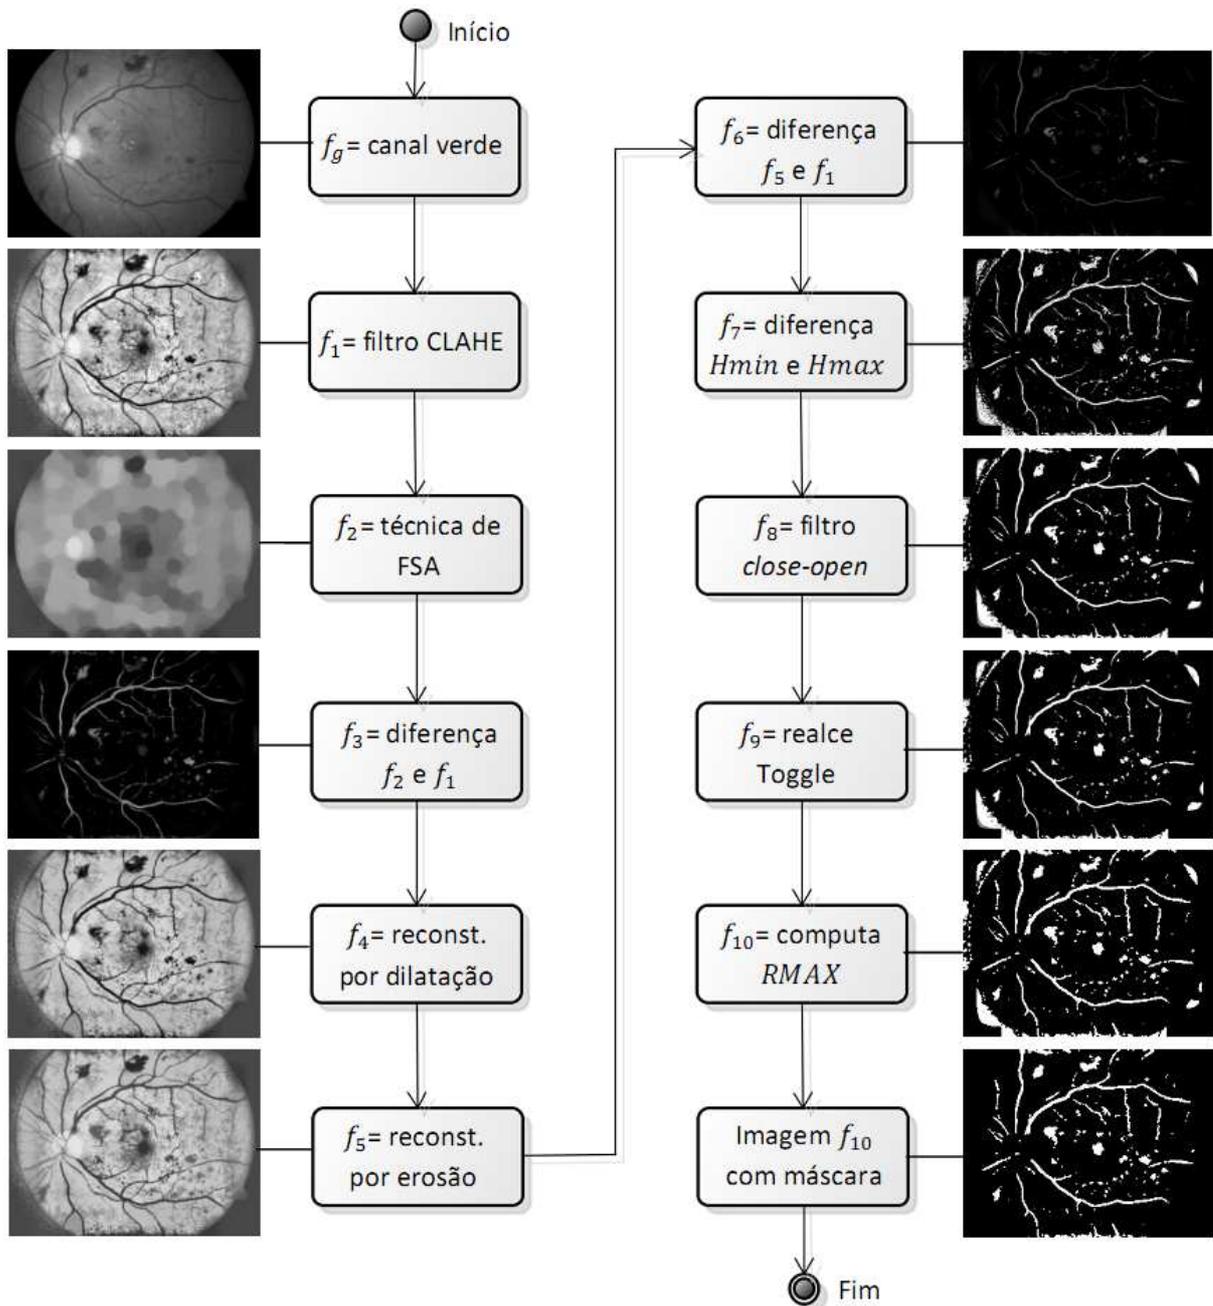
Além disso, é possível visualizar, através da Figura 4.3, as imagens resultantes de cada passo realizado. Por fim, a Figura 4.4 apresenta um fluxograma que mostra, de forma resumida, o método de obtenção de candidatos à lesão vermelha. A entrada do fluxograma é a imagem original em tons de cinza f_g , e a saída é a imagem f_{10} contendo a detecção preliminar das lesões.

Figura 4.3 - Imagens resultantes de cada passo da detecção preliminar



(a) imagem f_g ; (b) imagem f_1 ; (c) imagem f_2 ; (d) imagem f_3 ; (e) imagem f_4 ; (f) imagem f_5 ; (g) imagem f_6 ; (h) imagem f_7 ; (i) imagem f_8 ; (j) imagem f_9 ; (k) imagem f_{10} sem a máscara aplicada; (l) imagem f_{10} com a máscara aplicada.

Figura 4.4 - Passos resumidos para detectar os candidatos à lesão



4.3 Método para a detecção refinada das lesões vermelhas

Para identificar e remover da imagem f_{10} aquelas regiões que são vasos sanguíneos, foi calculada a circularidade da forma das regiões. A ideia é que as regiões que pertencem à rede de vasos têm uma forma mais alongada do que as lesões e, portanto, são pouco circulares. Dessa forma, entre as n formas de contorno, foram selecionadas aquelas mais circulares, como está descrito na Equação 4.13 (SOPHARAK et al., 2008).

$$f_{11} = \begin{cases} \text{região mantida,} & \text{se } 4\pi \frac{A}{P^2} > \lambda \\ \text{região removida,} & \text{caso contrário} \end{cases} \quad (4.13)$$

onde P é a forma do contorno do perímetro, ou seja, o número total de pixels em torno da fronteira de cada região, A é o número de pixels da região e λ é o limiar utilizado para remover as formas alongadas indesejáveis. Neste passo, o limiar utilizado foi $\lambda = 0.1$.

Agora, é realizada a união das imagens resultantes dos métodos f_3 e f_6 , como mostra a Equação 4.14. Essa operação resulta no realce das lesões que foram identificadas nas imagens f_3 e f_6 .

$$f_{12}(x,y) = f_3(x,y) \vee f_6(x,y) \quad (4.14)$$

Em seguida, é descrito o passo para melhorar a precisão da detecção das lesões vermelhas, baseado nos pixels de primeiro plano da imagem binária f_{11} . Utilizando as imagens f_{11} e f_{12} , o método descrito na Equação 4.15 resultará na imagem f_{13} , que será utilizada posteriormente como imagem marca.

$$f_{13}(x,y) = \begin{cases} 0, & \text{se } \delta^{(B)}(f_{11}(x,y)) = 1 \\ f_{12}, & \text{caso contrário} \end{cases} \quad (4.15)$$

onde B é o elemento estruturante na forma de cruz com raio de valor 15. A dilatação que utiliza esse elemento estruturante grande garante que as regiões de lesões vermelhas sejam incluídas na imagem resultante f_{13} .

Após, utilizando f_{13} como imagem marca, e utilizando f_{12} como imagem máscara, a imagem reconstruída f_{14} é obtida, como mostra a Equação 4.16. Dessa forma, apenas as regiões que não são lesões vermelhas são reconstruídas.

$$f_{14} = \mathcal{R}_{f_{12}}(f_{13}) \quad (4.16)$$

Então, a região das lesões vermelhas é realçada através da subtração da imagem reconstruída f_{14} e da imagem f_{12} , de acordo com a Equação 4.17.

$$f_{15} = f_{12} - f_{14} \quad (4.17)$$

Agora, os mesmos passos descritos na Equação 4.7, Equação 4.8, Equação 4.9 e Equação 4.11 são aplicados. O processo é basicamente o mesmo, como mostram as equações abaixo, mudando somente as imagens que sofrem as operações morfológicas e, em alguns casos, o elemento estruturante utilizado.

$$f_{16} = (Hmin_h(f_{15}) - Hmax_h(f_{15}))^c \quad (4.18)$$

$$f_{17} = \gamma^{(B)}(\phi^{(B)}(f_{16})), \quad (4.19)$$

onde B é o elemento estruturante utilizado. Nesse caso, para a operação de fechamento, utilizou-se um elemento estruturante na forma de disco com raio de valor 1, e na operação de abertura, o elemento estruturante na forma de disco com um raio de valor 2.

$$f_{18} = \begin{cases} \varepsilon^{(B)}(f_{17}), & \text{se } f_{17(x,y)} - \varepsilon^{(B)}(f_{17}) \geq \delta^{(B)}(f_{17}) - f_{17(x,y)} \\ \delta^{(B)}(f_{17}), & \text{se } f_{17(x,y)} - \varepsilon^{(B)}(f_{17}) < \delta^{(B)}(f_{17}) - f_{17(x,y)} \end{cases} \quad (4.20)$$

Em adição, a imagem f_{18} também sofreu as operações de fechamento de buracos, definida na Equação 4.10, seguida por uma dilatação com um elemento estruturante em forma de cruz, com raio 3.

$$f_{19} = RMAX(f_{18}) = f_{18} + 1 - \mathcal{R}_{f_{18}+1}(f_{18}) \quad (4.21)$$

Finalmente, para realizar a detecção final das lesões vermelhas, a região da fóvea é removida. O método utilizado é baseado na relação espacial entre o diâmetro do disco óptico e a região da fóvea. Utilizando essa relação espacial, é selecionada uma região de interesse na imagem da retina onde, dentro dessa região, as regiões candidatas são detectadas através de filtros morfológicos específicos que removem as lesões brancas e vermelhas antes de encontrar as regiões candidatas. Depois, o centro da região candidata mais escura, que é localizado abaixo do centro do disco óptico, é selecionado como o centro da fóvea (WELFER; SHARCANSKI; MARINHO, 2010).

Neste trabalho, o método de detecção da fóvea foi aplicado previamente em todas as imagens, ou seja, antes de realizar os passos para detectar as lesões vermelhas, as imagens com os resultados de detecção da fóvea já foram obtidas.

Como esse método retorna uma imagem binária contendo um pixel de cor branca que representa o centro da fóvea, foi necessário realizar a dilatação binária desse pixel para que toda a região da fóvea fosse subtraída da imagem f_{19} , como mostra a Equação 4.22.

$$f_{20} = f_{19} - \left(\delta^{(B)}(f_{fovea}) \right) \quad (4.22)$$

onde f_{19} é a imagem da detecção refinada das lesões vermelhas onde a fóvea ainda não foi removida, B é o elemento estruturante utilizado na dilatação, na forma de disco com raio de valor 50 e f_{fovea} é a imagem binária que contém o centro da fóvea detectado.

Ainda, nessa imagem f_{20} , algumas operações morfológicas binárias foram aplicadas, como a operação de fechamento de buracos (definida na Equação 4.10), seguida pelo operador de abertura da imagem e, por fim, a dilatação utilizando um elemento estruturante em forma de cruz, com um raio de valor 1.

É possível visualizar através do Algoritmo 2 todos os passos realizados no segundo estágio de detecção de lesões.

Algoritmo 2: Pseudocódigo da segunda fase de detecção de lesões vermelhas

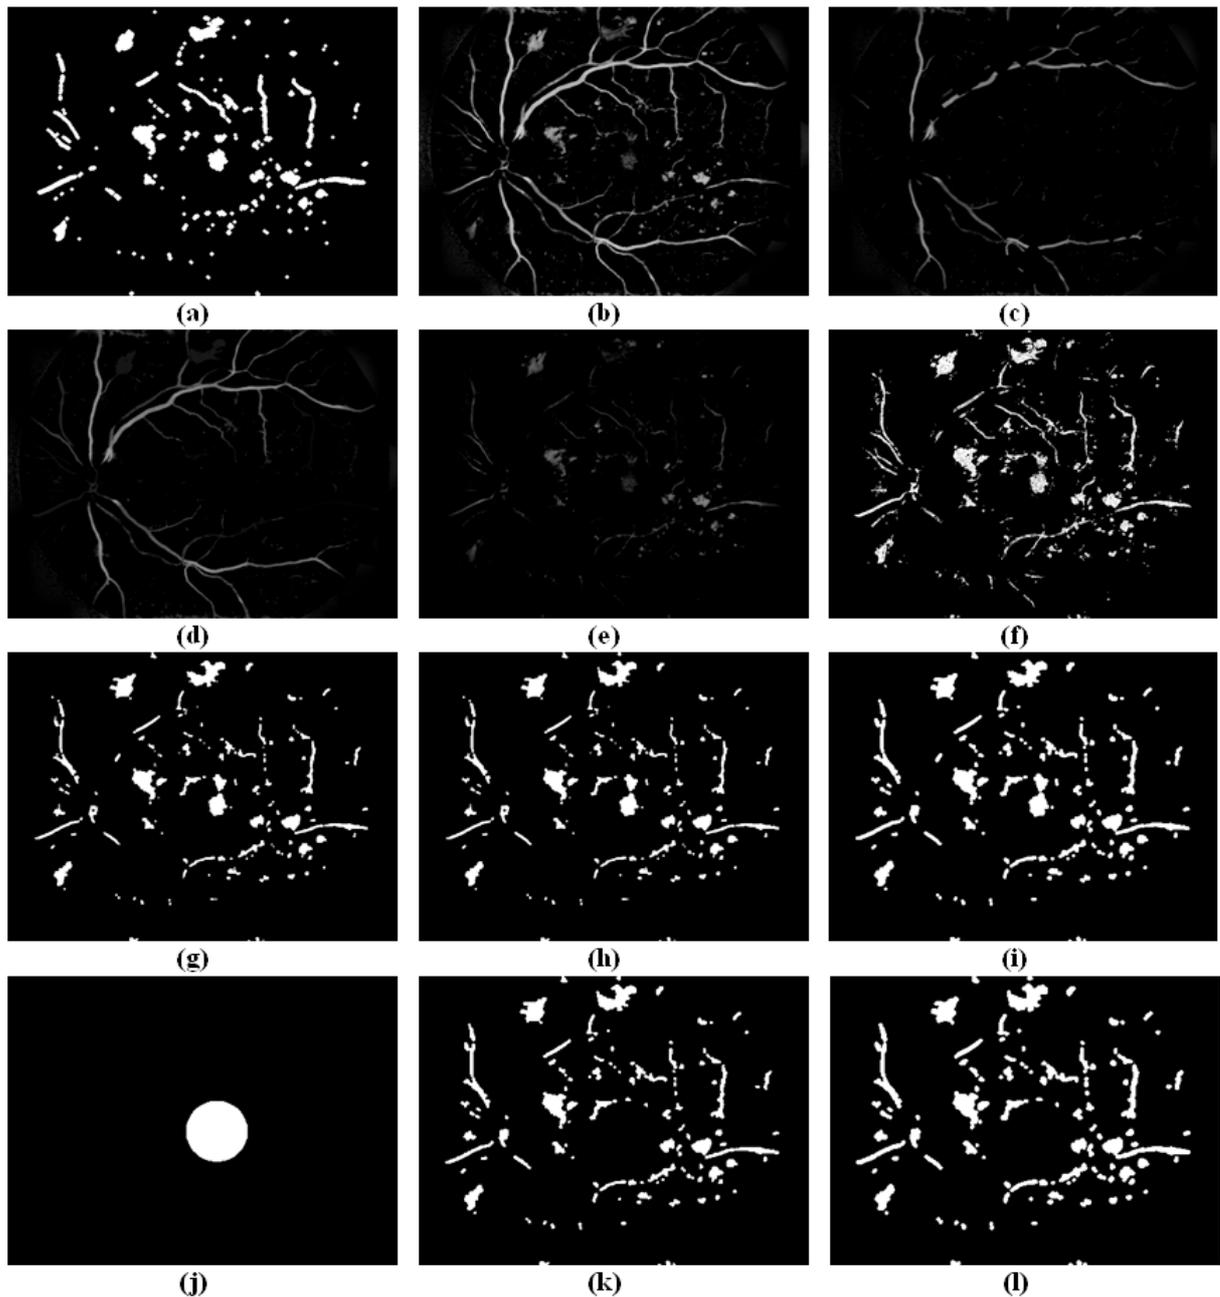
Entrada: imagem binária contendo os candidatos à lesão detectados (imagem f_{10}).

Saída: imagem binária com a detecção final das lesões vermelhas (imagem f_{20}).

1. $f_{11} = \begin{cases} \text{região mantida,} & \text{se } 4\pi \frac{A}{P^2} > \lambda \\ \text{região removida,} & \text{caso contrário} \end{cases};$
 2. $f_{12(x,y)} = f_{3(x,y)} \vee f_{6(x,y)};$
 3. $f_{13(x,y)} = \begin{cases} 0, & \text{se } \delta^{(B)}(f_{11(x,y)}) = 1; \\ f_{12}, & \text{caso contrário} \end{cases};$
 4. $f_{14} = \mathcal{R}_{f_{12}}(f_{13});$
 5. $f_{15} = f_{12} - f_{14};$
 6. $f_{16} = (Hmin_h(f_{15}) - Hmax_h(f_{15}))^c;$
 7. $f_{17} = \gamma^{(B)}(\phi^{(B)}(f_{16}));$
 8. $f_{18} = \begin{cases} \varepsilon^{(B)}(f_{17}), & \text{se } f_{17(x,y)} - \varepsilon^{(B)}(f_{17}) \geq \delta^{(B)}(f_{17}) - f_{17(x,y)}; \\ \delta^{(B)}(f_{17}), & \text{se } f_{17(x,y)} - \varepsilon^{(B)}(f_{17}) < \delta^{(B)}(f_{17}) - f_{17(x,y)}; \end{cases};$
 9. $f_{18} = \delta^{(B)}(FILL(f_{18}));$
 10. $f_{19} = RMAX(f_{18}) = f_{18} + 1 - \mathcal{R}_{f_{18}+1}(f_{18});$
 11. $f_{20} = f_{19} - \left(\delta^{(B)}(f_{fovea}) \right);$
 12. $f_{20} = \delta^{(B)}\left(\gamma^{(B)}(FILL(f_{20})) \right).$
-

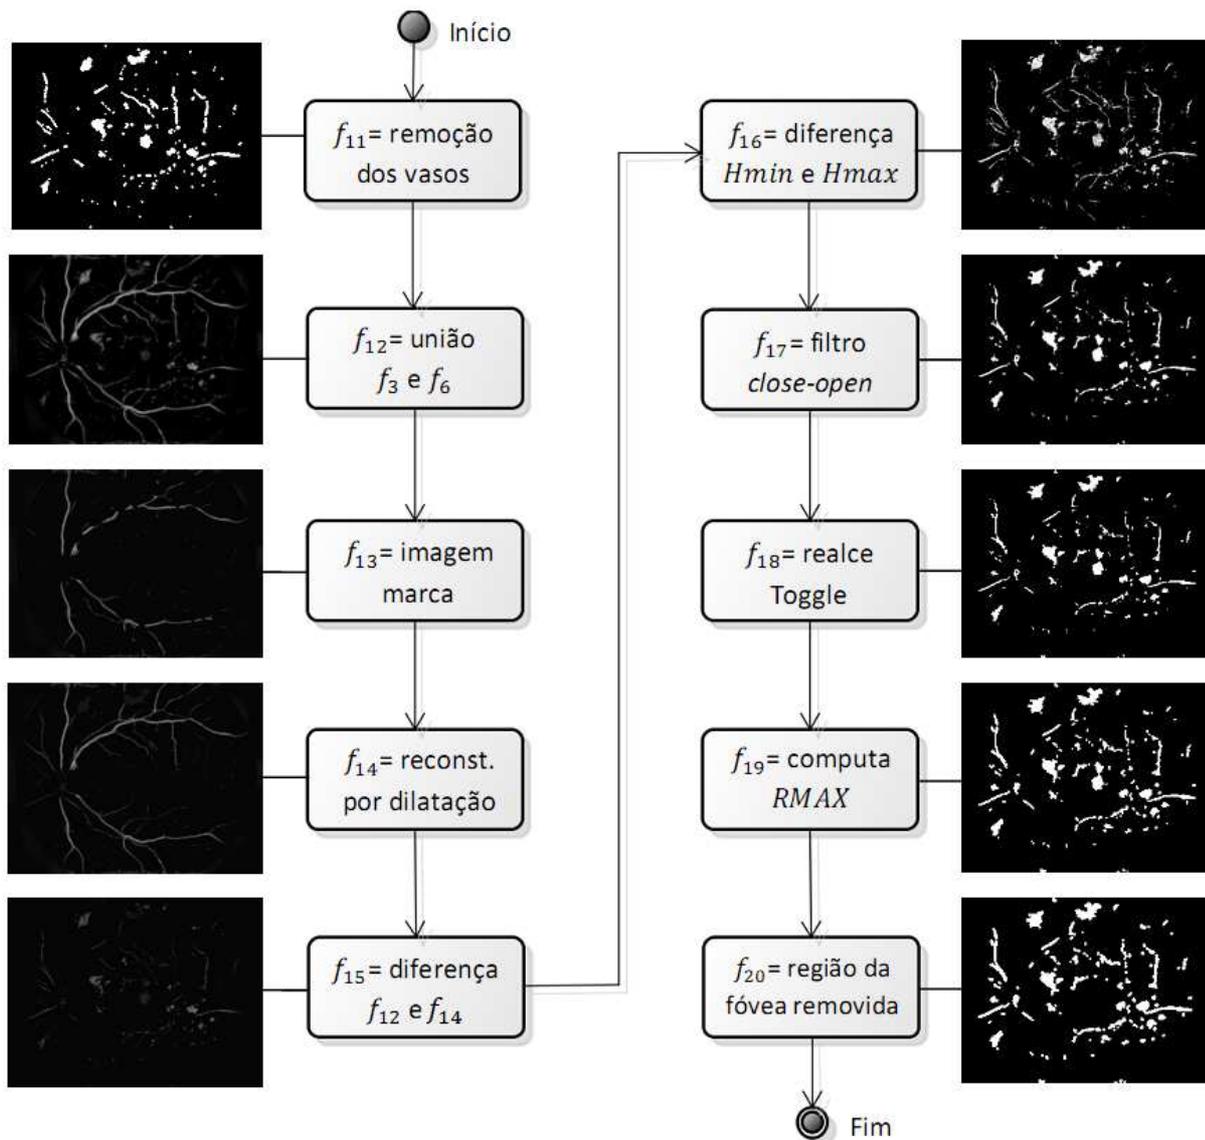
A Figura 4.5 apresenta as imagens resultantes de cada passo realizado. Em adição, a Figura 4.6 apresenta um fluxograma que mostra, de forma resumida, o método de detecção refinada das lesões vermelhas apresentado nesta seção. A entrada do fluxograma é a imagem f_{10} que representa os candidatos à lesão vermelha. A saída é a imagem final da detecção das lesões vermelhas.

Figura 4.5 - Imagens resultantes de cada passo da detecção refinada



(a) imagem f_{11} ; (b) imagem f_{12} ; (c) imagem f_{13} ; (d) imagem f_{14} ; (e) imagem f_{15} ; (f) imagem f_{16} ; (g) imagem f_{17} ; (h) imagem f_{18} ; (i) imagem f_{19} ; (j) imagem resultante da operação $\delta^{(B)}(f_{fovea})$; (k) imagem f_{20} ; (l) imagem f_{20} com as operações de fechamento de buracos, abertura morfológica e dilatação aplicadas.

Figura 4.6 - Passos resumidos para detectar o conjunto final das lesões vermelhas



4.4 Conclusão

Este capítulo apresentou as imagens de fundo do olho utilizadas para testar o método elaborado, bem como a solução desenvolvida para o problema da detecção automática de lesões vermelhas em imagens de fundo do olho, utilizando morfologia matemática. Especificamente, a solução foi dividida em duas etapas, a saber: detecção preliminar das lesões, e detecção refinada das lesões. O objetivo da primeira etapa da solução era obter os candidatos à lesão vermelha, isto é, aquelas regiões que são prováveis lesões. Isso também incluiu os vasos sanguíneos e a região da fóvea, visto que eles possuem a mesma intensidade que as lesões vermelhas. Na segunda etapa de detecção ocorreu a detecção final das lesões

vermelhas através da remoção dos vasos sanguíneos e da região da fóvea, além do aumento da precisão das lesões detectadas anteriormente. Em adição, o capítulo apresentou os passos da detecção de lesões na forma de algoritmo, e também na forma de fluxograma, com o resultado do processamento da imagem de cada passo.

5 RESULTADOS EXPERIMENTAIS

Neste capítulo são apresentadas as medidas utilizadas para quantificar o método, bem como os resultados obtidos através do método apresentado anteriormente.

A seção 5.1 descreve as cinco medidas utilizadas para quantificar o método desenvolvido. A seção 5.2 apresenta os resultados obtidos do método de detecção das lesões vermelhas, bem como uma análise dos mesmos. Por fim, a seção 5.3 faz o fechamento do capítulo.

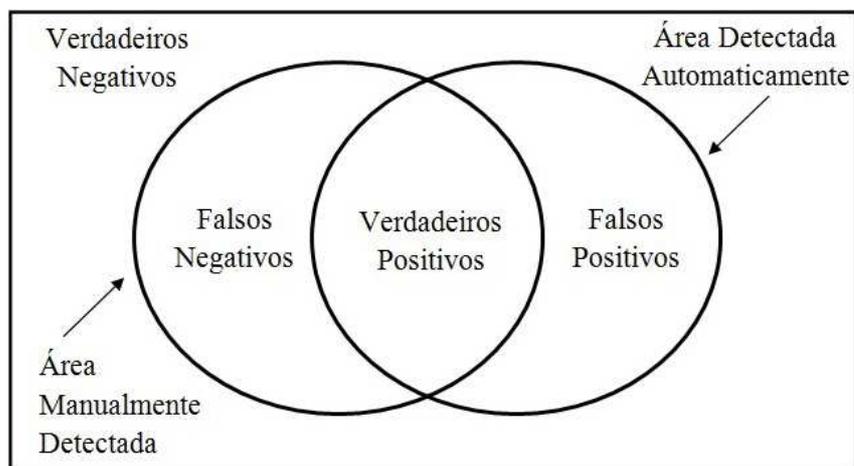
5.1 Medidas utilizadas para a quantificação do método

Para realizar a quantificação do método desenvolvido, cinco medidas foram utilizadas: sensibilidade (*sensitivity*), especificidade (*specificity*), valor preditivo (*predictive value*), sobreposição (*overlap*) e proporção incorretamente classificada (*misclassified proportion*).

Quando uma lesão vermelha é detectada na imagem, ela pode estar realmente presente (verdadeiro positivo - VP), como pode não existir (falso positivo - FP). Da mesma forma, quando não for detectada uma lesão vermelha na imagem, a mesma pode realmente não existir (verdadeiro negativo - VN), como pode estar presente e não ter sido detectada (falso negativo - FN) (OBID, 2012). A Figura 5.1 ilustra de forma intuitiva as áreas utilizadas para quantificar as medidas (WELFER, 2011).

Dessa forma, a sensibilidade e especificidade podem ser encontradas de acordo com a Equação 5.1 e 5.2, respectivamente (OBID, 2012).

Figura 5.1 - Áreas usadas para encontrar as medidas utilizadas



Fonte: Welfer (2011).

$$\text{Sensitividade} = \frac{VP}{VP+FN} \quad (5.1)$$

$$\text{Especificidade} = \frac{VN}{VN+FP} \quad (5.2)$$

A sensibilidade é a fração dos que obtiveram resposta positiva no teste entre aqueles que possuem as lesões vermelhas. A especificidade é a fração dos que obtiveram resposta negativa no teste entre aqueles que não possuem as lesões vermelhas (OBID, 2012). Resumidamente, a sensibilidade é a proporção de verdadeiros positivos, e a especificidade é a proporção de verdadeiros negativos.

O valor preditivo é a probabilidade de que um pixel que foi classificado como lesão seja realmente uma lesão, e pode ser calculado de acordo com a Equação 5.3 (WALTER et al., 2002).

$$\text{Valor preditivo} = \frac{VP}{VP+FP} \quad (5.3)$$

A sobreposição da área entre o *ground truth* das lesões vermelhas e as lesões vermelhas obtidas através do método desenvolvido é estimada de acordo com a Equação 5.4 (WELFER et al., 2010).

$$\text{Sobreposição} = \frac{VP}{VP+FN+FP} \quad (5.4)$$

Por fim, a proporção incorretamente classificada é definida de acordo com a Equação 5.5 (SOPHARAK et al., 2008).

$$\text{Proporção incorretamente classificada} = \frac{FP}{(VP+FP+FN+VN)} \quad (5.5)$$

5.2 Resultados da detecção automática de lesões vermelhas

O método de detecção preliminar das lesões vermelhas foi testado nas 89 imagens do DIARETDB1, utilizando as medidas de sensibilidade, especificidade, valor preditivo, sobreposição e proporção incorretamente classificada, descritas na seção 5.1. Além disso, a quantificação do método ocorreu nos dois estágios de detecção de lesões (detecção preliminar

e detecção refinada), e aplicado nos dois conjuntos de imagens: imagens com lesões e imagens sem lesões.

A Tabela 5.1 mostra a média de pixels de VP, FN, FP e VN. Através desses valores, é possível realizar a quantificação do método utilizando as cinco medidas citadas anteriormente.

Tabela 5.1 - Média de VP, FN, FP e VN nos estágios de detecção preliminar e refinada

Estágio de detecção	Imagens da retina com lesões			
	Verdadeiro positivo	Falso negativo	Falso positivo	Verdadeiro negativo
Preliminar	1423.34	716.01	20630.23	284430.4
Refinada	1661.79	477.56	19842.58	285218.1
Estágio de detecção	Imagens da retina sem lesões			
	Verdadeiro positivo	Falso negativo	Falso positivo	Verdadeiro negativo
Preliminar	0	0	19215.61	287984.4
Refinada	0	0	16430.81	290769.2

Realizando a análise dessa tabela, é possível notar o aumento dos pixels de verdadeiro positivo e verdadeiro negativo no estágio de detecção refinada. Em contrapartida, percebe-se que os pixels de falso negativo e falso positivo diminuíram nessa fase de detecção. De fato, o número de falsos negativos tende a diminuir na detecção refinada, pois a imagem marca f_{13} é o resultado da dilatação das lesões detectadas na imagem f_{11} , que é a imagem que contém os candidatos à lesão, porém sem os vasos sanguíneos. Essa dilatação acarreta na diminuição de pixels do tipo falso negativo, pois a área de pesquisa por novas lesões é ampliada, ou seja, a área de pixels do tipo verdadeiro positivo. Se o número de falsos negativos diminui, consequentemente o número de pixels verdadeiro positivo aumenta. Uma vez que esses pixels de VP aumentam na fase de detecção refinada, o valor da sensibilidade nessa fase também tende a aumentar.

Já a diminuição dos pixels de FP na fase de detecção refinada resulta no aumento da especificidade, da sobreposição e também do valor preditivo nessa fase. Além disso, a proporção incorretamente classificada tende a diminuir, já que o número de falsos positivos diminuiu.

Essa análise realizada pode ser comprovada através da Tabela 5.2, que indica os resultados atingidos nos estágios de detecção preliminar e detecção refinada. Em imagens com lesões vermelhas presentes, o método atingiu 64.63% de sensibilidade e 93.23% de especificidade no estágio de detecção dos candidatos à lesão, e 75.82% de sensibilidade e 93.49% de especificidade no estágio final de detecção. Já nas imagens sem lesões vermelhas, foi alcançada uma especificidade de 93.74% no estágio de detecção dos candidatos à lesão, e

94.65% de especificidade no estágio final da detecção. A quantificação do método em imagens sem lesões vermelhas não gera sensibilidade, valor preditivo e sobreposição, pois as medidas de VP e FN nesse caso são iguais a zero.

Tabela 5.2 - Resultados do método nos estágios de detecção preliminar e refinada

Estágio de detecção	Imagens da retina com lesões				
	Sensitividade	Especificidade	Valor preditivo	Proporção incorretamente classificada	Sobreposição
Preliminar	64,63%	93,23%	5.80%	6.72%	5.46%
Refinada	75,82%	93,49%	6.58%	6.46%	6.36%
Estágio de detecção	Imagens da retina sem lesões				
	Sensitividade	Especificidade	Valor preditivo	Proporção incorretamente classificada	Sobreposição
Preliminar		93,74%		6.26%	
Refinada		94,65%		5.35%	

Os resultados alcançados em cada imagem com lesão podem ser visualizados no Apêndice B (resultados da detecção preliminar) e Apêndice D (resultados da detecção refinada). Já os resultados obtidos em cada imagem sem lesão estão disponíveis para visualização no Apêndice C (detecção preliminar) e Apêndice E (detecção refinada).

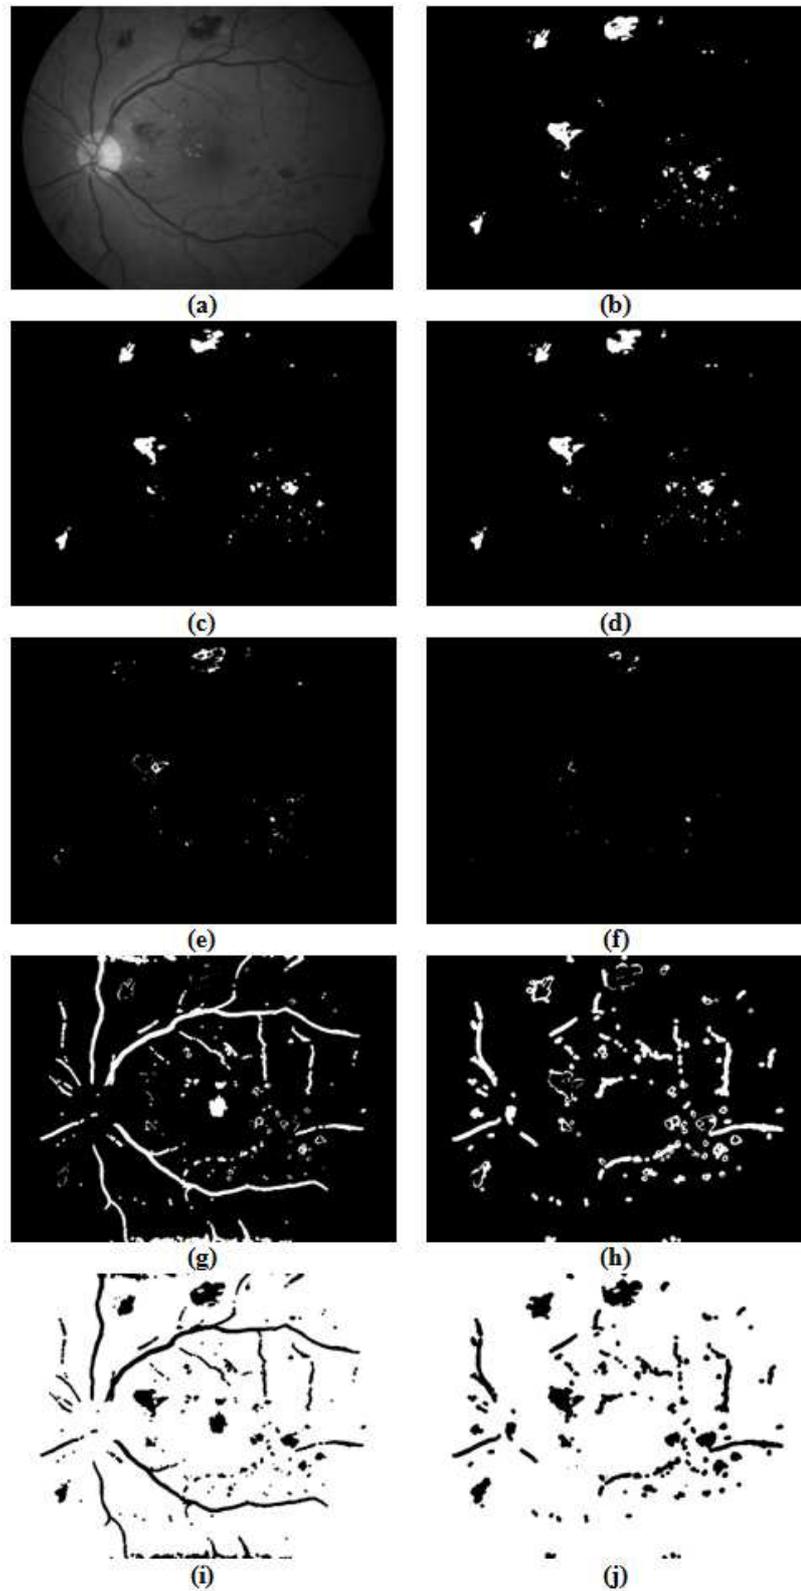
Outra informação que pode ser apresentada é o tempo de processamento médio por imagem. A Tabela 5.3 apresenta o tempo médio de processamento de uma imagem, referente a este trabalho e também de outros da literatura que reportaram essa medida. As especificações de máquina mencionadas na tabela são aquelas reportadas pelos autores. Para mais informações, o Apêndice F apresenta detalhadamente o tempo de processamento de cada imagem utilizada neste trabalho.

Tabela 5.3 - Tempo médio de processamento por imagem

Autor(es)	Média por imagem	Ferramenta utilizada	Especificações de máquina
Niemeijer et al. (2005)	15 minutos	Não descrito	Máquina de 1.7GHz e Processador Intel Pentium IV
Ravishankar et al. (2009)	20 segundos	Não descrito	Máquina de 2 GHz 448 MB de RAM
Esmaeili et al. (2010)	3 minutos	MATLAB	Máquina de 1.8 GHz
Kande et al. (2010)	35 segundos	MATLAB	Processador Intel Pentium IV
Este trabalho (2013)	19 segundos	MATLAB	Máquina de 2.1 GHz e Processador Intel Pentium Dual-Core

Para um melhor entendimento sobre as medidas atingidas na Tabela 5.1, a Figura 5.2 apresenta as ilustrações dos pixels de VP, FN, FP e VN encontrados nos estágios de detecção preliminar e refinada, onde os pixels de cor branca representam esses valores.

Figura 5.2 - Detecção de VP, FN, FP e VN nas detecções preliminar e refinada



(a) Imagem original tons de cinza número 08; (b) *Ground truth* da imagem; (c) VP da detecção preliminar; (d) VP da detecção refinada; (e) FN da detecção preliminar; (f) FN da detecção refinada; (g) FP da detecção preliminar; (h) FP da detecção refinada; (i) VN da detecção preliminar; (j) VN da detecção refinada. (sensitividade = 92.18%; especificidade = 93.88%)

O método desenvolvido baseado em morfologia matemática apresenta algumas características positivas que devem ser mencionadas. Primeiramente, o método descrito utiliza operadores morfológicos adaptativos. Um exemplo é o operador de máximos regionais, aplicado nos dois estágios de detecção de lesões vermelhas (detecção preliminar e detecção refinada), pois ele se adapta de acordo com a imagem que é processada. Dessa forma, descarta-se o uso de limiarização básica no método porque ela não leva em consideração determinados aspectos da imagem.

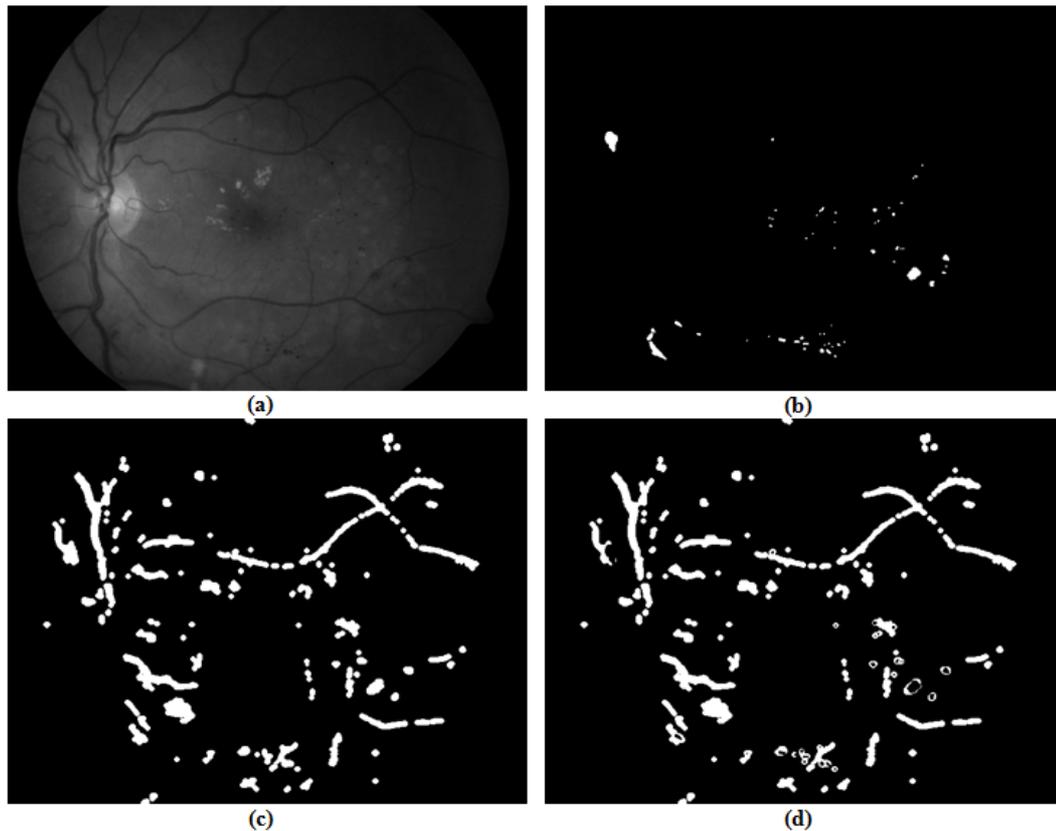
Outro aspecto importante é que o método apresentado neste trabalho não sofre influência de lesões brancas ou do disco óptico na fase de detecção, pois ele tenta identificar as lesões vermelhas discriminando regiões de baixa e alta intensidade, onde as regiões de baixa intensidade são associadas a possíveis lesões vermelhas. Alguns métodos da literatura realizam primeiramente a detecção de todas as estruturas presentes na imagem para, posteriormente, remover o disco óptico e as lesões brancas.

Além disso, de certa forma a complexidade do método é baixa, se comparada aos outros métodos descritos na literatura. Isso pode ser comprovado pelo tempo de processamento médio de uma imagem, descrito anteriormente. Desse modo, o método desenvolvido pode ser uma opção interessante na análise de um grande número de imagens.

Porém, o método apresenta certas limitações, e todas relacionadas aos problemas da detecção de lesões vermelhas apresentados na Introdução deste trabalho, como a remoção dos vasos sanguíneos e a identificação de lesões pequenas na imagem.

A detecção e remoção dos vasos sanguíneos tornaram-se um problema, pois ele afetou tanto a sensibilidade quanto a especificidade do método. A etapa de extração dos vasos sanguíneos contribuiu para a perda de sensibilidade, pois nessa fase muitas lesões foram perdidas devido à proximidade com os vasos. Assim, quando a circularidade é calculada, as lesões são removidas, pois muitas delas estavam grudadas aos vasos sanguíneos. Essa é a desvantagem em relação a um método de detecção de vasos sanguíneos que procura identificar o esqueleto da árvore dos vasos sanguíneos baseado na sua estrutura linear. Em relação à especificidade, a remoção dos vasos sanguíneos causou problema devido a pequenos vasos que não foram removidos da imagem. Esses pixels são identificados como FP e acabam diminuindo a especificidade do método. A Figura 5.3 mostra que a maioria dos FP detectados na imagem encontra-se na área dos vasos.

Figura 5.3 - Problemas na detecção e remoção dos vasos sanguíneos

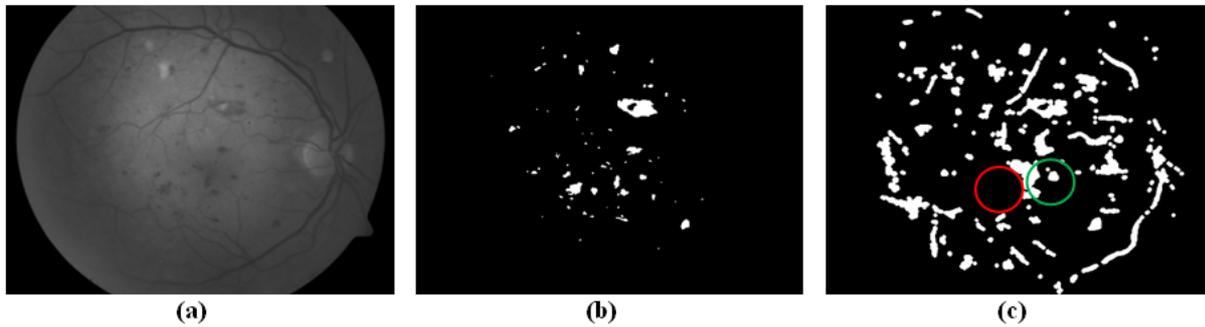


(a) Imagem tons de cinza número 09; (b) *Ground truth* da imagem; (c) Detecção final das lesões vermelhas (sensitividade = 63.20%; especificidade = 94.04%); (d) Falsos positivos detectados.

Outro fator que afetou a sensibilidade foi o tamanho das lesões. Muitas lesões que possuem tamanho muito pequeno não foram identificadas com o método, ou foram perdidas nas etapas de detecção refinada por se parecerem com ruído na imagem. Em algumas imagens que continham apenas poucas lesões de tamanho pequeno, isso resultou em uma baixa sensibilidade.

Por fim, o problema de detecção da região fóvea não afetou de forma significativa na sensibilidade do método, pois a região da fóvea foi mal detectada em apenas uma imagem, onde ela foi confundida com uma lesão grande. De qualquer forma, a Figura 5.4 mostra a única imagem em que toda a região foi incorretamente detectada, onde a Figura 5.4 (a) apresenta a imagem original tons de cinza, a figura 5.4 (b) mostra o *ground truth* da imagem, e a Figura 5.4 (c) mostra a detecção final das lesões vermelhas, onde o círculo verde representa a região aproximada da fóvea que deveria ser retirada, e o círculo vermelho representa a região que, de fato, foi removida da imagem erroneamente.

Figura 5.4 - Problema na remoção da região da fóvea



(a) Imagem original tons de cinza número 64; (b) *Ground truth* da imagem; (c) Detecção final das lesões vermelhas, onde o círculo verde representa a região aproximada da fóvea que deveria ser retirada, e o círculo vermelho representa a região que, de fato, foi removida da imagem erroneamente (sensitividade = 79.44%; especificidade = 92.05%).

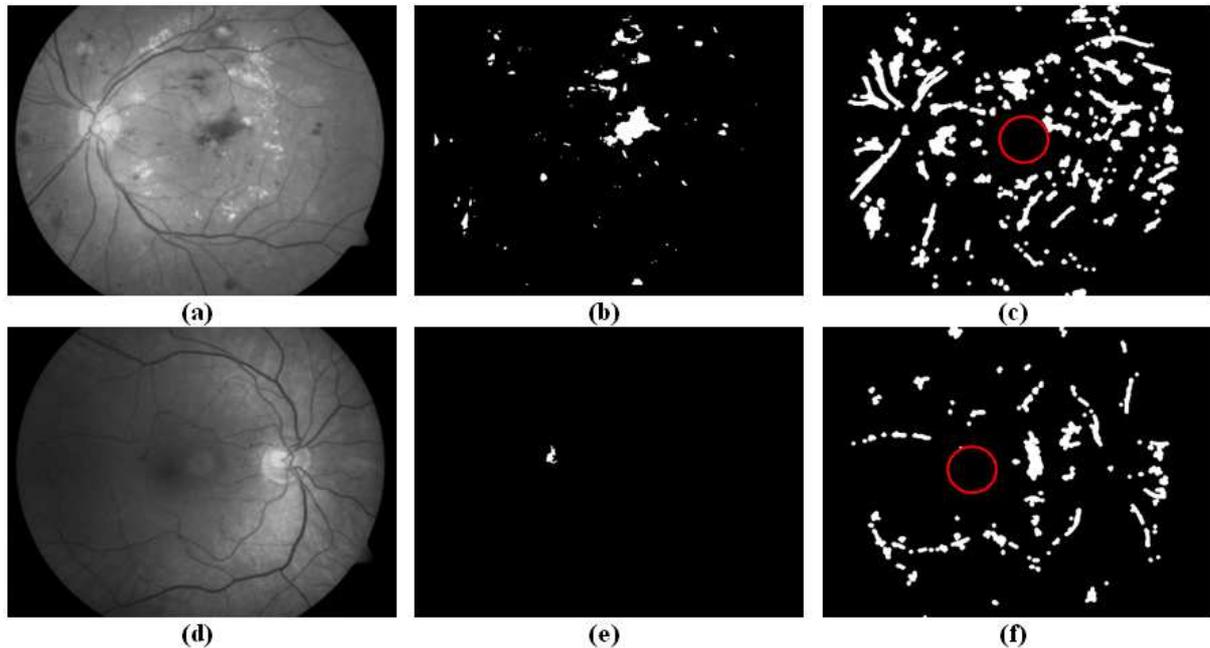
Sendo assim, tanto a perda de lesões pequenas quanto a perda de lesões que ficavam grudadas aos vasos sanguíneos contribuíram significativamente na redução da sensibilidade.

No entanto, outro problema que não depende do método elaborado foi encontrado. O problema está relacionado à presença de lesões na região da fóvea, que ocorreu em 17 das 53 imagens com lesão. No estágio de detecção preliminar, essas lesões foram detectadas, porém elas foram removidas na etapa de remoção da fóvea. O caso mais grave ocorreu em uma imagem que possuía apenas uma lesão, situada na região da fóvea, o que levou a uma sensibilidade quase igual a zero nessa imagem. Como a região da fóvea possui intensidade, e até mesmo forma, semelhante a uma lesão, ficaria difícil elaborar um método que detectasse essa região e, ao mesmo tempo, verificasse a presença ou ausência de lesões. O que poderia ser feito é não extrair a região da fóvea, porém isso diminuiria a especificidade do método.

A Figura 5.5 apresenta duas imagens que tiveram esse problema, onde a primeira coluna apresenta as imagens tons de cinza número 05 e 58, respectivamente, a segunda coluna mostra o *ground truth* dessas imagens, e a terceira coluna apresenta a detecção refinada das lesões vermelhas, onde o círculo vermelho representa a região da fóvea extraída da imagem.

Devido às suas desvantagens, o método não atingiu uma alta medida de sensibilidade se comparada às medidas reportadas na literatura. No entanto, quando analisada sua especificidade, é possível perceber que está entre as melhores apresentadas. Isso significa que, apesar de o método falhar em detectar pequenas lesões (pelos motivos citados anteriormente), a detecção resultante contém menos falsos positivos que a maioria dos trabalhos relacionados. Além disso, embora a medida de sensibilidade não seja tão alta, essa comparação com os demais trabalhos deve ser feita com cautela. Como mencionado no capítulo de Trabalhos Relacionados, muitos autores utilizam imagens que não estão disponíveis, ou seja, imagens

Figura 5.5 - Problemas com lesões vermelhas na região da fóvea



(a) Imagem original tons de cinza número 05; (b) *Ground truth* da imagem 05; (c) Detecção final das lesões vermelhas, onde o círculo vermelho representa a região aproximada da fóvea que foi retirada (sensitividade = 50.65%; especificidade = 89.17%); (d) Imagem tons de cinza número 58; (e) *Ground truth* da imagem 58; (f) Detecção final das lesões vermelhas, onde o círculo vermelho representa a região aproximada da fóvea que foi retirada (sensitividade = 4.76%; especificidade = 95.33%).

não públicas. Como afirmado por Garcia et al. (2008), a falta de um banco de imagens público é uma desvantagem no processo de comparação com os trabalhos da literatura.

5.3 Conclusão

Este capítulo apresentou os resultados obtidos na detecção automática de lesões vermelhas em imagens de fundo do olho. Os resultados foram satisfatórios e comparáveis aos demais reportados pela literatura, embora não seja possível realizar uma comparação exata, devido ao tipo de imagem que alguns autores utilizam (imagens não públicas). O método elaborado é baseado em operadores morfológicos que, de certa forma, pode ser útil na análise de um grande número de imagens. Porém, suas limitações referem-se principalmente à detecção e extração de vasos sanguíneos e detecção de lesões pequenas. De qualquer forma, as medidas atingidas mostram que o método poderia auxiliar no trabalho de especialistas em oftalmologia.

6 CONSIDERAÇÕES FINAIS

Este trabalho teve por objetivo realizar a detecção automática de lesões vermelhas (microaneurismas e hemorragias) em imagens de fundo do olho. Para atingir esse objetivo, foi desenvolvido um método de detecção baseado em operadores morfológicos, que é composto por dois estágios de detecção: detecção preliminar e detecção refinada. A fase de detecção preliminar tem por objetivo detectar os pixels candidatos à lesão, e a fase de detecção refinada objetiva melhorar a detecção com base nos candidatos à lesão detectados anteriormente. O capítulo 1 realizou a introdução do trabalho, descrevendo a motivação, os objetivos, os problemas da detecção de lesões vermelhas e o método de trabalho. No capítulo 2 foram apresentados nove trabalhos da literatura relacionados à detecção de lesões vermelhas. O capítulo 3 descreveu os operadores morfológicos necessários para o entendimento do método. Já no capítulo 4 foram apresentados os materiais utilizados para testar o método, e todos os passos realizados para detectar automaticamente as lesões vermelhas. Por fim, o capítulo 5 apresentou todos os resultados alcançados com esse método. O método atingiu um valor médio em sensibilidade (75,82%) e um alto valor em especificidade (93,49%). Esse valor médio em sensibilidade deve-se a diversos problemas que ocorrem em detecção de lesões vermelhas, a saber: detecção e remoção dos vasos sanguíneos, detecção de lesões pequenas, e detecção e remoção da fóvea. De qualquer forma, cabe ressaltar que os objetivos propostos neste trabalho foram atingidos.

A detecção de lesões vermelhas tem por finalidade auxiliar o especialista em oftalmologia. Como o método possui falhas, é importante deixar claro que não é possível utilizar, de forma isolada, o método desenvolvido. Apesar disso, o método desenvolvido e apresentado neste trabalho poderia ser utilizado para analisar grandes volumes de imagem, devido ao tempo médio de processamento de uma imagem, se comparada a outros trabalhos relacionados. Esse método poderia ser utilizado para auxiliar um programa de triagem real, pois Javitt et al. (1990) afirmam que alcançar uma sensibilidade maior ou igual a 60% aumenta a rentabilidade na triagem de RD. Porém, como dito anteriormente, seu funcionamento deve ser assistido por um especialista em oftalmologia, pois ele é apenas um mecanismo de auxílio.

Os resultados desse trabalho foram apresentados no IV Salão Internacional de Ensino, Pesquisa e Extensão (SIEPE), onde o mesmo foi premiado como o melhor resumo da área de Ciências Exatas e da Terra, na categoria de pesquisa – apresentação oral. Em adição, o

trabalho foi submetido para o 26th IEEE International Symposium on Computer-Based Medical Systems (CBMS).

Trabalhos futuros se concentrarão em resolver as falhas ocorridas no processo de detecção, como a correta detecção e remoção dos vasos sanguíneos e a detecção das lesões pequenas. Uma detecção mais precisa dos vasos sanguíneos que não remova lesões vermelhas é o primeiro passo para aumentar as medidas de sensibilidade e especificidade alcançadas neste trabalho.

REFERÊNCIAS

ABRÀMOFF, M. D.; GARVIN, M. K.; SONKA, M. Retinal Imaging and Image Analysis. **IEEE Reviews In Biomedical Engineering**, [s. L.], v. 3, p. 169-208. dez. 2010.

AKRAM, M. U.; TARIQ, A.; NASIR, S. Retinal Images: Noise Segmentation. In: IEEE INTERNATIONAL MULTITOPIC CONFERENCE, 12., 2008, Karachi. **Proceedings...** Karachi: IEEE, 2008. p. 116-119.

AMERICAN DIABETES ASSOCIATION. Economic Costs of Diabetes in the U.S. in 2002. **Diabetes Care**, [s. L.], p. 917-932. mar. 2003.

BADEA, P.; DANCIU, D.; DAVIDESCU, L. Preliminary results on using an extension of gradient method for detection of red lesions on eye fundus photographs. In: IEEE INTERNATIONAL CONFERENCE ON AUTOMATION, QUALITY AND TESTING, ROBOTICS, 2008, Cluj- napoca. **Proceedings...** Cluj- napoca: IEEE Computer Society, 2008. p. 43-48.

BALASUBRAMANIAN, S; PRADHAN, S.; CHANDRASEKARAN, V. Red Lesions Detection in Digital Fundus Images. In: IEEE INTERNATIONAL CONFERENCE ON IMAGE PROCESSING, 15., 2008, San Diego. **Proceedings...** San Diego: IEEE Computer Society, 2008. p. 2932 - 2935.

CIULLA, T. A.; AMADOR, A. G.; ZINMAN, B. Diabetic Retinopathy and Diabetic Macular Edema: Pathophysiology, screening, and novel therapies. **Diabetes Care**, [s. L.], v. 26, n. 9, p. 2653-2664. set. 2003.

DOUGHERTY, E. R.; LOTUFO, R. A. **Hands-on Morphological Image Processing**. [s. L.]: SPIE Publications, 2003.

ESMAEILI, M. et al. A new curvelet transform based method for extraction of red lesions in digital color retinal images. In: IEEE INTERNATIONAL CONFERENCE ON IMAGE PROCESSING, 17., 2010, Hong Kong. **Proceedings...** Hong Kong: IEEE Computer Society, 2010. p. 4093-4096.

FACON, J. **Morfologia Matemática: teoria e exemplos**. Curitiba: Gráfica Universitária Champagnat da Pontifícia Universidade Católica do Paraná, 1996.

FANG, G. et al. Automatic Segmentation of Hard Exudates in Fundus Images Based on Boosted Soft Segmentation. In: INTERNATIONAL CONFERENCE ON INTELLIGENT CONTROL AND INFORMATION PROCESSING, 2010, Dalian. **Proceedings...** Dalian: IEEE, 2010. p. 633-638.

FONG, D. S. et al. Diabetic Retinopathy. **Diabetes Care**, [s. L.], v. 26, n. 1, p. 226-229. jan. 2003.

GARCIA, M. et al. Automatic Detection of Red Lesions in Retinal Images Using a Multilayer Perceptron Neural Network. In: ANNUAL INTERNATIONAL IEEE EMBS CONFERENCE, 30., 2008, Vancouver. **Proceedings...** Vancouver: IEEE, 2008. p. 5425 - 5428.

HOOVER, A.; GOLDBAUM, M. Locating the optic nerve in a retinal image using the fuzzy convergence of the blood vessels. **IEEE Transactions on Medical Imaging**, [s. L.], v. 22, n. 8, p. 951-958. ago. 2003.

HOOVER, A.; KOUZNETSOVA, V.; GOLDBAUM, M. Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response. **IEEE Transactions on Medical Imaging**, [s. L.], v. 19, n. 3, p. 203-210. mar. 2000.

ISHIKAWA, A. S. **Detecção de rodovias em imagens digitais de alta resolução com o uso da teoria de Morfologia Matemática**. 2008. 113 f. Dissertação (Mestrado) - Universidade Estadual Paulista, Presidente Prudente, 2008.

JAAFAR, H. F.; NANDI, A. K.; AL-NUAIMY, W. Automated Detection of Red Lesions from Digital Colour Fundus Photographs. In: IEEE INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 33., 2011, Boston. **Proceedings...** Boston: IEEE, 2011. p. 6232-6235.

JAVITT, J. C.; CANNER, J. K.; FRANK, R. G.; STEINWACHS, D. M.; SOMMER, A. Detecting and treating retinopathy in patients with type I diabetes mellitus. A health policy model. **Ophthalmology**, v. 97, n. 4, p. 483-494. abr. 1990.

JÄHNE, B.; HAUBECKER, H.; GEISLER, P. **Handbook of Computer Vision and Applications: signal processing and pattern recognition**. New York: Academic Press, 1999. v.2.

KANDE, G. B.; SAVITHRI, T. S.; SUBBAIAH, P. V. Automatic Detection of Microaneurysms and Hemorrhages in Digital Fundus Images. **Journal Of Digital Imaging**, v. 23, n. 4, [s. L.], p. 430-437. ago. 2010.

KAUPPI, T. et al. **DIARETDB0: Evaluation database and morphology for diabetic retinopathy algorithm**. Technical report, Lappeenranta University of Technology, Finland, 2006.

KAUPPI, T. et al. **DIARETDB1 diabetic retinopathy database and evaluation protocol**. Technical report, 2007.

KURT, B. et al. Medical images enhancement by using anisotropic filter and CLAHE. In: IEEE INTERNATIONAL SYMPOSIUM ON INNOVATIONS IN INTELLIGENT SYSTEMS AND APPLICATIONS, 6., 2012, Trabzon. **Proceedings...** Trabzon: IEEE, 2012. p. 1-4.

MARIÑO, C. et al. Automated three stage red lesions detection in digital color fundus images. **Wseas Transactions on Computers**, Stevens Point, v. 7, n. 4, p. 207-215. abr. 2008.

MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento Digital de Imagens**. Rio de Janeiro: Brasport, 1999.

MathWorks. **MATLAB and Simulink for Technical Computing**. Disponível em: <<http://www.mathworks.com/>>. Acesso em: 15 jan. 2013.

MMORPH. **SDC Morphology Toolbox for MATLAB**. Disponível em: <<http://www.mmorph.com>>. Acesso em: 30 jan. 2013.

NIEMEIJER, M. et al. Automatic Detection of Red Lesions in Digital Color Fundus Photographs. **IEEE Transactions on Medical Imaging**, [s. L], v. 26, n. 1, p. 584-592. maio 2005.

OBID - OBSERVATÓRIO BRASILEIRO DE INFORMAÇÕES SOBRE DROGAS. **Sensibilidade e Especificidade**. Disponível em: <http://www.obid.senad.gov.br/portais/OBID/conteudo/index.php?id_conteudo=11450&rastr_o=PESQUISAS+E+ESTAT%C3%8DSTICAS%2FConceitos+Estat%C3%ADsticos/Sensibilidade+e+Especificidade>. Acesso em: 12 fev. 2013.

RAVISHANKAR, S.; JAIN, A.; MITTAL, A. Automated feature extraction for early detection of diabetic retinopathy in fundus images. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2009, Miami. **Proceedings...** Miami: IEEE Computer Society, 2009. p. 210-217.

SALAZAR-GONZALEZ, A. G.; LI, Y.; LIU, X. Optic Disc Segmentation by Incorporating Blood Vessel Compensation. In: INTERNATIONAL WORKSHOP ON COMPUTATIONAL INTELLIGENCE IN MEDICAL IMAGING, 3., 2011, Paris. **Proceedings...** Paris: IEEE, 2011. p. 1-8.

SILBERMAN, N. et al. Case for Automated Detection of Diabetic Retinopathy. In: AAAI SPRING SYMPOSIUM SERIES, 2010, Palo Alto. **Proceedings...** Palo Alto: Aaai Press, 2010.

SOILLE, P. **Morphological Image Analysis: Principles and Applications**. 2. ed. Heidelberg: Springer, 2003.

SOPHARAK, A. et al. Automatic Detection of Diabetic Retinopathy Exudates from Non-Dilated Retinal Images Using Mathematical Morphology Methods. **Computerizes Medical Imaging and Graphics**, [s. L.], v.32, p. 720-727, ago. 2008.

STAAL, J. et al. Ridge based vessel segmentation in color images of the retina. **IEEE Transactions on Medical Imaging**, [s. L.], v. 23, n. 4, p. 501-509. abr. 2004.

TARIQ, A.; AKRAM, M. U. An Automated System for Colored Retinal Image Background and Noise Segmentation. In: IEEE SYMPOSIUM ON INDUSTRIAL ELECTRONICS AND APPLICATIONS, 2010, Penang. **Proceedings...** Penang: IEEE, 2010. p. 423-427.

WALTER, T. et al. A Contribution of Image Processing to the Diagnosis of Diabetic Retinopathy – Detection of Exudates in Color Fundus Images of the Human Retina. **IEEE Transactions on Medical Imaging**, [s. L.], v. 21, n. 10, p. 1236-1243, out. 2002.

WELFER, D. **Métodos Computacionais para Identificar Automaticamente Estruturas da Retina e Quantificar a Severidade do Edema Macular Diabético em Imagens de Fundo do Olho**. 2011. 91 f. Tese (Doutorado) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

WELFER, D.; SHARCANSKI, J.; MARINHO, D. R. Fovea center detection based on the retina anatomy and mathematical morphology. **Computer Methods and Programs in Biomedicine**, [s. L.], v. 104, n. 3, p.397-409, jul. 2010.

WELFER, D. et al. Segmentation of the Optic Disk in Color Eye Fundus Images Using an Adaptive Morphological Approach. **Computers in Biology and Medicine**, [s. L.], v. 40, n. 2, p. 124-137, fev. 2010.

WORLD HEALTH ORGANIZATION. **Prevention of blindness from diabetes mellitus: report of a WHO consultation in Geneva, Switzerland**. [s. L.], 2005.

WORLD HEALTH ORGANIZATION; INTERNATIONAL DIABETES FEDERATION. **Diabetes Action Now: An initiative of the World Health Organization and the International Diabetes Federation**. [s. L.], 2004.

ZUIDERVELD, K. Contrast limited adaptive histogram equalization. **Graphic Gems IV**. San Diego: Academic Press Professional, 1994. p. 474-485.

APÊNDICE A – Imagens que tiveram seu *ground truth* modificado

Imagem	Marcações que não foram consideradas	Especialistas que identificaram	Tipo da imagem
28	1	1	Sem lesão
31	4	1	Sem lesão
32	2	1	Com lesão
34	1	1	Sem lesão
37	2	1	Com lesão
38	3	2	Sem lesão
39	3	1	Sem lesão
40	2	1	Sem lesão
46	1	1	Sem lesão
47	1	1	Sem lesão
48	2	1	Sem lesão
50	2	1	Sem lesão
51	2	1	Sem lesão
56	5	2	Sem lesão
59	2	1	Sem lesão
61	3	1	Sem lesão
63	3	1	Com lesão
68	2	1	Sem lesão
69	2	1	Sem lesão
70	3	1	Sem lesão
71	2	1	Sem lesão
73	1	1	Sem lesão
74	1	1	Sem lesão
75	1	1	Sem lesão
76	1	1	Sem lesão
77	2	1	Sem lesão
78	4	2	Sem lesão
79	3	1	Sem lesão
80	1	1	Sem lesão
81	1	1	Sem lesão
82	3	1	Sem lesão
83	3	1	Sem lesão
88	2	1	Sem lesão
89	4	1	Com lesão

Legenda: Marcações que não foram consideradas = número de objetos marcados na imagem que não foram considerados como lesão quando o *ground truth* foi modificado; Especialistas que identificaram = número de especialistas em oftalmologia que identificaram essas marcações como sendo lesão.

APÊNDICE B – Resultado da detecção preliminar em cada imagem com lesão

Imagem	SE	ES	Predit.	VP	FN	FP	VN	Overlap	PIC
1	0,510345	0,941009	0,008108	148	142	18105	288805	0,008046	0,058936
2	0,868966	0,941864	0,007009	126	19	17851	289204	0,007002	0,058109
3	0,650794	0,936109	0,032445	656	352	19563	286629	0,03189	0,063682
4	0,77686	0,932317	0,02647	564	162	20743	285731	0,02627	0,067523
5	0,571073	0,922154	0,12805	3443	2586	23445	277726	0,116815	0,076318
6	0,6231	0,913928	0,007702	205	124	26413	280458	0,007666	0,08598
7	0,519902	0,937284	0,109099	2325	2147	18986	283742	0,099113	0,061803
8	0,775897	0,930833	0,155524	3850	1112	20905	281333	0,148838	0,06805
9	0,492827	0,941372	0,031525	584	601	17941	288074	0,030534	0,058402
10	0,683874	0,91266	0,124547	3749	1733	26352	275366	0,117767	0,085781
11	0,600329	0,928179	0,104977	2552	1699	21758	281191	0,09812	0,070827
12	0,489362	0,929028	0,002106	46	48	21796	285310	0,002101	0,070951
13	0,619824	0,941861	0,026983	494	303	17814	288589	0,026543	0,057988
14	0,55752	0,929679	0,09011	2113	1677	21336	282074	0,084096	0,069453
15	0,773038	0,910763	0,065984	1921	564	27192	277523	0,06473	0,088516
16	0,667073	0,909273	0,153408	4929	2460	27201	272610	0,142498	0,088545
17	0,892421	0,917028	0,014136	365	44	25455	281336	0,014112	0,082861
18	0,753372	0,932251	0,053611	1173	384	20707	284936	0,052686	0,067406
19	0,608237	0,916542	0,085378	2363	1522	25314	278001	0,080927	0,082402
20	0,659951	0,934337	0,265633	7043	3629	19471	277057	0,233653	0,063382
21	0,643399	0,930504	0,157047	3899	2161	20928	280212	0,144472	0,068125
22	0,70589	0,948654	0,262661	5477	2282	15375	284066	0,236751	0,050049
23	0,656906	0,955141	0,140126	2221	1160	13629	290190	0,13057	0,044365
24	0,818396	0,923717	0,082221	2082	462	23240	281416	0,080748	0,075651
25	0,700101	0,893166	0,097369	3483	1492	32288	269937	0,093471	0,105104
26	0,582976	0,934463	0,146751	3397	2430	19751	281622	0,132809	0,064294
27	0,557895	0,947703	0,047361	795	630	15991	289784	0,045648	0,052054
29	0,929157	0,897999	0,038405	1246	95	31198	274661	0,038293	0,101556
30	0,636364	0,946434	0,000425	7	4	16455	290734	0,000425	0,053564
32	0	0,954094	0	0	9	14102	293089	0	0,045905
35	0,633065	0,928266	0,00708	157	91	22019	284933	0,007051	0,071676
36	0,596045	0,929492	0,009659	211	143	21635	285211	0,009596	0,070426
37	1	0,948779	0,000191	3	0	15735	291462	0,000191	0,051221
41	0,748436	0,945575	0,034619	598	201	16676	289725	0,03422	0,054284
42	0,825893	0,959235	0,014568	185	39	12514	294462	0,014523	0,040736
43	0,358333	0,939696	0,002317	43	77	18518	288562	0,002307	0,06028
44	0,668675	0,935642	0,005586	111	55	19760	287274	0,005571	0,064323
45	0,782609	0,94913	0,001151	18	5	15626	291551	0,00115	0,050866
52	0,61747	0,916107	0,0079	205	127	25744	281124	0,007862	0,083802
53	0,378205	0,944118	0,013588	236	388	17132	289444	0,013291	0,055768
54	0,318584	0,931037	0,00339	72	154	21170	285804	0,003365	0,068913
55	0,646259	0,923955	0,023885	570	312	23294	283024	0,023577	0,075827
58	0,506494	0,94664	0,007092	117	114	16380	290589	0,007044	0,05332
63	0,423948	0,949713	0,01671	262	356	15417	291165	0,016339	0,050186
64	0,754138	0,926427	0,112322	2825	921	22326	281128	0,108354	0,072676
65	0,714628	0,930111	0,089329	2086	833	21266	283015	0,086252	0,069225
66	0,700044	0,894665	0,047481	1601	686	32118	272795	0,046534	0,104551
67	0,800129	0,933483	0,109134	2478	619	20228	283875	0,106238	0,065846
84	0,789785	0,921268	0,057588	1469	391	24040	281300	0,056718	0,078255
85	0,734625	0,93696	0,043248	872	315	19291	286722	0,042582	0,062796
86	0,376923	0,942857	0,002785	49	81	17547	289523	0,002772	0,057119
87	0,555556	0,940055	0,000543	10	8	18414	288768	0,000543	0,059941
89	1	0,950367	0,000197	3	0	15247	291950	0,000197	0,049632

Média 0,646334 0,932338 0,058029 1423,34 716,0189 20630,23 284430,4 0,054582 0,067156

Legenda: SE = sensibilidade; ES = especificidade; Predit. = valor preditivo; VP = verdadeiro positivo; FN = falso negativo; FP = falso positivo; VN = verdadeiro negativo; Overlap = sobreposição; PIC = proporção incorretamente classificada.

APÊNDICE C – Resultado da detecção preliminar em cada imagem sem lesão

Imagem	SE	ES	Predit.	VP	FN	FP	VN	Overlap	PIC
28		0,928408		0	0	21993	285207		0,071592
31		0,937103		0	0	19322	287878		0,062897
33		0,928617		0	0	21929	285271		0,071383
34		0,918623		0	0	24999	282201		0,081377
38		0,944749		0	0	16973	290227		0,055251
39		0,939857		0	0	18476	288724		0,060143
40		0,932767		0	0	20654	286546		0,067233
46		0,940163		0	0	18382	288818		0,059837
47		0,922617		0	0	23772	283428		0,077383
48		0,937409		0	0	19228	287972		0,062591
49		0,951634		0	0	14858	292342		0,048366
50		0,923275		0	0	23570	283630		0,076725
51		0,937464		0	0	19211	287989		0,062536
56		0,937832		0	0	19098	288102		0,062168
57		0,91264		0	0	26837	280363		0,08736
59		0,930771		0	0	21267	285933		0,069229
60		0,913643		0	0	26529	280671		0,086357
61		0,942907		0	0	17539	289661		0,057093
62		0,942721		0	0	17596	289604		0,057279
68		0,953711		0	0	14220	292980		0,046289
69		0,956611		0	0	13329	293871		0,043389
70		0,950977		0	0	15060	292140		0,049023
71		0,946309		0	0	16494	290706		0,053691
72		0,933262		0	0	20502	286698		0,066738
73		0,934775		0	0	20037	287163		0,065225
74		0,935749		0	0	19738	287462		0,064251
75		0,923659		0	0	23452	283748		0,076341
76		0,947965		0	0	15985	291215		0,052035
77		0,957985		0	0	12907	294293		0,042015
78		0,935413		0	0	19841	287359		0,064587
79		0,945026		0	0	16888	290312		0,054974
80		0,934525		0	0	20114	287086		0,065475
81		0,944967		0	0	16906	290294		0,055033
82		0,940244		0	0	18357	288843		0,059756
83		0,932591		0	0	20708	286492		0,067409
88		0,951201		0	0	14991	292209		0,048799
Média		0,937449				19215,61	287984,4		0,062551

Legenda: SE = sensibilidade; ES = especificidade; Predit. = valor preditivo; VP = verdadeiro positivo; FN = falso negativo; FP = falso positivo; VN = verdadeiro negativo; Overlap = sobreposição; PIC = proporção incorretamente classificada.

APÊNDICE D – Resultado da detecção refinada em cada imagem com lesão

Imagem	SE	ES	Predit.	VP	FN	FP	VN	Overlap	PIC
1	0,686207	0,941227	0,010912	199	91	18038	288872	0,010858	0,058717
2	0,737931	0,944899	0,006285	107	38	16919	290136	0,006271	0,055075
3	0,77381	0,942144	0,042174	780	228	17715	288477	0,04166	0,057666
4	0,913223	0,930696	0,03027	663	63	21240	285234	0,030183	0,069141
5	0,506552	0,891723	0,085633	3054	2975	32610	268561	0,079039	0,106152
6	0,784195	0,949148	0,016264	258	71	15605	291266	0,016192	0,050798
7	0,777728	0,9315	0,14363	3478	994	20737	281991	0,137967	0,067503
8	0,921806	0,938876	0,198455	4574	388	18474	283764	0,19517	0,060137
9	0,632068	0,940483	0,0395	749	436	18213	287802	0,038612	0,059287
10	0,811018	0,938903	0,194318	4446	1036	18434	283284	0,185901	0,060007
11	0,731828	0,931863	0,130973	3111	1140	20642	282307	0,124975	0,067194
12	0,457447	0,960427	0,003526	43	51	12153	294953	0,003511	0,039561
13	0,791719	0,943783	0,035338	631	166	17225	289178	0,035013	0,056071
14	0,7	0,927919	0,108184	2653	1137	21870	281540	0,10339	0,071191
15	0,878471	0,924982	0,087174	2183	302	22859	281856	0,086135	0,074411
16	0,787928	0,922715	0,200807	5822	1567	23171	276640	0,19051	0,075426
17	0,963325	0,927879	0,017496	394	15	22126	284665	0,017484	0,072025
18	0,890816	0,943156	0,07393	1387	170	17374	288269	0,073266	0,056556
19	0,657915	0,929492	0,106758	2556	1329	21386	281929	0,101144	0,069616
20	0,788793	0,905415	0,230852	8418	2254	28047	268481	0,217413	0,091299
21	0,74703	0,92375	0,164684	4527	1533	22962	278178	0,155985	0,074746
22	0,798814	0,925975	0,218516	6198	1561	22166	277275	0,207118	0,072155
23	0,805383	0,946922	0,144464	2723	658	16126	287693	0,139591	0,052493
24	0,863601	0,927006	0,089912	2197	347	22238	282418	0,088653	0,072389
25	0,801809	0,918941	0,140029	3989	986	24498	277727	0,135344	0,079746
26	0,669813	0,920331	0,139827	3903	1924	24010	277363	0,130811	0,078158
27	0,863158	0,927532	0,052589	1230	195	22159	283616	0,052154	0,072132
29	0,771066	0,909788	0,036121	1034	307	27592	278267	0,035738	0,089818
30	0,636364	0,935655	0,000354	7	4	19766	287423	0,000354	0,064342
32	0	0,951587	0	0	9	14872	292319	0	0,048411
35	0,741935	0,960173	0,014828	184	64	12225	294727	0,014752	0,039795
36	0,966102	0,939246	0,018015	342	12	18642	288204	0,018004	0,060684
37	1	0,925709	0,000131	3	0	22822	284375	0,000131	0,07429
41	0,876095	0,944289	0,039392	700	99	17070	289331	0,039174	0,055566
42	0,928571	0,948634	0,01302	208	16	15768	291208	0,013007	0,051328
43	0,45	0,947724	0,003353	54	66	16053	291027	0,003339	0,052256
44	0,86747	0,948937	0,009101	144	22	15678	291356	0,009089	0,051035
45	0,782609	0,944869	0,001062	18	5	16935	290242	0,001061	0,055127
52	0,792169	0,948304	0,016308	263	69	15864	291004	0,016239	0,051641
53	0,75641	0,955013	0,03309	472	152	13792	292784	0,032741	0,044896
54	0,783186	0,951937	0,011855	177	49	14754	292220	0,011816	0,048027
55	0,946712	0,948025	0,049833	835	47	15921	290397	0,049694	0,051826
58	0,047619	0,953318	0,000767	11	220	14330	292639	0,000755	0,046647
63	0,898058	0,959903	0,043197	555	63	12293	294289	0,042987	0,040016
64	0,794447	0,920581	0,109913	2976	770	24100	279354	0,106874	0,078451
65	0,85406	0,9411	0,122116	2493	426	17922	286359	0,11962	0,05834
66	0,903367	0,909771	0,069849	2066	221	27512	277401	0,069331	0,089557
67	0,85825	0,925397	0,104873	2658	439	22687	281416	0,103087	0,073851
84	0,964516	0,880471	0,046852	1794	66	36497	268843	0,046771	0,118805
85	0,614153	0,909782	0,025726	729	458	27608	278405	0,025317	0,08987
86	0,484615	0,939418	0,003375	63	67	18603	288467	0,003363	0,060557
87	0,722222	0,945127	0,000771	13	5	16856	290326	0,00077	0,05487
89	1	0,946295	0,000182	3	0	16498	290699	0,000182	0,053704
Média	0,758158	0,934882	0,065785	1661,792	477,566	19842,58	285218,1	0,063557	0,064592

Legenda: SE = sensibilidade; ES = especificidade; Predit. = valor preditivo; VP = verdadeiro positivo; FN = falso negativo; FP = falso positivo; VN = verdadeiro negativo; Overlap = sobreposição; PIC = proporção incorretamente classificada.

APÊNDICE E – Resultado da detecção refinada em cada imagem sem lesão

Imagem	SE	ES	Predit.	VP	FN	FP	VN	Overlap	PIC
28		0,938385		0	0	18928	288272		0,061615
31		0,948926		0	0	15690	291510		0,051074
33		0,958219		0	0	12835	294365		0,041781
34		0,955365		0	0	13712	293488		0,044635
38		0,932044		0	0	20876	286324		0,067956
39		0,950596		0	0	15177	292023		0,049404
40		0,942773		0	0	17580	289620		0,057227
46		0,95057		0	0	15185	292015		0,04943
47		0,928203		0	0	22056	285144		0,071797
48		0,943675		0	0	17303	289897		0,056325
49		0,958522		0	0	12742	294458		0,041478
50		0,953089		0	0	14411	292789		0,046911
51		0,9454		0	0	16773	290427		0,0546
56		0,954447		0	0	13994	293206		0,045553
57		0,939209		0	0	18675	288525		0,060791
59		0,950465		0	0	15217	291983		0,049535
60		0,947956		0	0	15988	291212		0,052044
61		0,949479		0	0	15520	291680		0,050521
62		0,94209		0	0	17790	289410		0,05791
68		0,909027		0	0	27947	279253		0,090973
69		0,921979		0	0	23968	283232		0,078021
70		0,958174		0	0	12849	294351		0,041826
71		0,947142		0	0	16238	290962		0,052858
72		0,941149		0	0	18079	289121		0,058851
73		0,935117		0	0	19932	287268		0,064883
74		0,953145		0	0	14394	292806		0,046855
75		0,951803		0	0	14806	292394		0,048197
76		0,95557		0	0	13649	293551		0,04443
77		0,943851		0	0	17249	289951		0,056149
78		0,95554		0	0	13658	293542		0,04446
79		0,950182		0	0	15304	291896		0,049818
80		0,95626		0	0	13437	293763		0,04374
81		0,950863		0	0	15095	292105		0,049137
82		0,946211		0	0	16524	290676		0,053789
83		0,96208		0	0	11649	295551		0,03792
88		0,947008		0	0	16279	290921		0,052992
Média		0,946514				16430,81	290769,2		0,053486

Legenda: SE = sensibilidade; ES = especificidade; Predit. = valor preditivo; VP = verdadeiro positivo; FN = falso negativo; FP = falso positivo; VN = verdadeiro negativo; Overlap = sobreposição; PIC = proporção incorretamente classificada.

APÊNDICE F – Tempo de processamento de cada imagem

Imagem	Tempo parcial do método (segundos)	Imagem	Tempo total do método (segundos)
1	4,49659062523372	1	20,85769007
2	3,72129259518704	2	19,01281235
3	3,78685016202413	3	17,69259265
4	3,76209754883821	4	20,42583968
5	3,76562644358877	5	23,37848973
6	3,76288897155620	6	18,63187649
7	3,72900102313017	7	19,54962426
8	3,65552140776455	8	19,93229303
9	3,63853148312813	9	18,67215888
10	3,75144487195719	10	21,16949498
11	3,71572086193218	11	21,75403814
12	3,62150391825126	12	16,7786309
13	3,67773257146880	13	22,01800083
14	3,65098355903627	14	20,06340083
15	3,76274525427449	15	22,24860108
16	3,67183136390145	16	20,43845405
17	3,73085419392936	17	19,59052551
18	3,70817277163666	18	19,43088641
19	3,73682481596611	19	22,71766251
20	3,73216720283641	20	25,1458266
21	3,77609874061621	21	22,41854921
22	3,72635447427583	22	21,0175472
23	4,39966700608061	23	20,457457
24	3,93979223564941	24	23,45967093
25	3,69185841599114	25	21,59933333
26	3,61139482510242	26	22,8967318
27	4,49291605786429	27	19,14508895
28	4,92323541819529	28	19,55133616
29	3,74348811619396	29	20,72343076
30	3,85284474671784	30	20,46993547
31	3,85034778115671	31	16,5896681
32	3,72251125907582	32	17,78677635
33	4,02583635881024	33	16,62648025
34	3,82448698063190	34	17,82419808
35	4,05371017894757	35	19,1535712
36	3,71975863318021	36	18,03579342
37	3,85310822840098	37	20,09831826
38	3,79365375769364	38	16,83586607
39	3,77009683318481	39	17,05650338
40	3,89222621491209	40	18,15056096
41	3,67999098589566	41	18,70398982
42	3,75796347723474	42	19,41055823
43	3,77970731535629	43	17,38806697
44	3,78102081309763	44	18,47037493
45	3,77261090794615	45	17,33934094
46	3,85180744035122	46	17,63193173
47	3,98384793733927	47	17,59561574
48	3,87650725943365	48	17,42109359
49	3,76705286205145	49	16,2086159
50	4,06166155753360	50	17,01456286
51	3,78680274509785	51	17,52362023

52	3,75993201292673	52	17,64900427
53	3,69811353958556	53	19,81812138
54	3,84245261851421	54	18,40159497
55	3,70379379405314	55	17,77414683
56	3,74685227378827	56	17,23968279
57	3,80257302817690	57	16,62887554
58	3,82150802445931	58	18,81930485
59	3,91197169844986	59	18,17652637
60	3,78687607024158	60	16,160344
61	3,83119378711169	61	16,60689804
62	3,83489475153286	62	17,85862423
63	3,67466318095228	63	19,01842416
64	3,67486409184610	64	20,1721166
65	3,58888498364605	65	17,37457221
66	3,78165287583658	66	18,85554556
67	3,72718353723426	67	20,306438
68	3,80010637034184	68	17,38791836
69	3,82467420416555	69	18,54162693
70	3,88993700392485	70	16,76346042
71	6,84683159609773	71	22,50477078
72	3,95918282549154	72	19,11540644
73	3,79079749892823	73	17,47221833
74	3,75986602029738	74	16,76177687
75	3,85907542859769	75	17,5053652
76	3,92556129175439	76	16,76689692
77	3,81006930203751	77	17,43026657
78	3,90985895664186	78	17,54691563
79	3,77910702684629	79	17,16119066
80	3,83691999200267	80	18,31086635
81	3,84973820479517	81	17,33311124
82	4,39456748675137	82	18,10536285
83	3,82590264474017	83	16,68632579
84	3,68894643011649	84	19,39594502
85	3,68177523105975	85	18,7237265
86	3,66550633700334	86	16,43773204
87	3,67881436175595	87	17,49380329
88	3,83771483656070	88	17,35596913
89	3,77269303210713	89	18,2829324
Média parcial	3,858604467	Média final	18,85457634

Legenda: Tempo parcial do método = refere-se apenas ao tempo de processamento da fase de detecção preliminar das lesões; Tempo total do método = refere-se ao tempo total de processamento (detecção preliminar + detecção refinada)