

UNIVERSIDADE FEDERAL DO PAMPA

SÉRGIO ANTÔNIO MARTINI BORTOLIN JÚNIOR

**DETECÇÃO AUTOMÁTICA DE MICROANEURISMAS E HEMORRAGIAS EM
IMAGENS DE FUNDO DO OLHO**

**Alegrete-RS
2013**

SÉRGIO ANTÔNIO MARTINI BORTOLIN JÚNIOR

**DETECÇÃO AUTOMÁTICA DE MICROANEURISMAS E HEMORRAGIAS EM
IMAGENS DE FUNDO DO OLHO**

Dissertação apresentada ao Programa de Pós-graduação *Stricto Sensu* em Engenharia Elétrica da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Daniel Welfer

**Alegrete-RS
2013**

Ficha catalográfica elaborada automaticamente com os dados fornecidos pelo(a) autor(a) através do Módulo de Biblioteca do Sistema GURI (Gestão Unificada de Recursos Institucionais) .

B739d Bortolin Júnior, Sérgio Antônio Martini
Detecção Automática de Microaneurismas e Hemorragias em Imagens de Fundo do Olho / Sérgio Antônio Martini Bortolin Júnior.
78 p.

Dissertação (Mestrado) - Universidade Federal do Pampa, Mestrado em Engenharia Elétrica, 2013.
"Orientação: Daniel Welfer".

1. Processamento de Imagens. 2. Morfologia Matemática. 3. Imagens de Fundo do Olho. I. Título.

SÉRGIO ANTÔNIO MARTINI BORTOLIN JÚNIOR

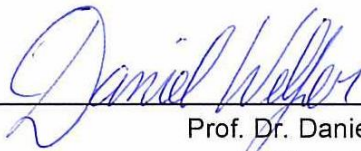
DETECÇÃO AUTOMÁTICA DE MICROANEURISMAS E HEMORRAGIAS EM IMAGENS DE FUNDO DO OLHO

Dissertação apresentada ao Programa de Pós-graduação Stricto Sensu em Engenharia Elétrica da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Mestre em Engenharia Elétrica.

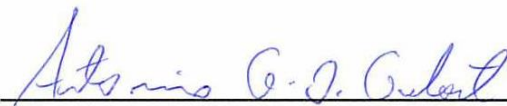
Área de concentração: Sistemas de Energia

Dissertação defendida e aprovada em: 13/12/2013.

Banca examinadora:



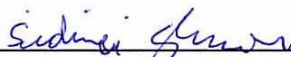
Prof. Dr. Daniel Welfer
Orientador
(UNIPAMPA)



Prof. Dr. Antonio Gledson Oliveira Goulart
(UNIPAMPA)



Prof. Dra. Isabel Harb Manssour
(PUC-RS)



Prof. Dr. Sidinei Ghissoni
(UNIPAMPA)

AGRADECIMENTOS

Primeiramente à minha família pelo apoio durante o curso de mestrado e compreensão pelo tempo que dediquei a este projeto ao longo deste ano.

Ao meu orientador, prof. Daniel Welfer, pelos trabalhos de revisão e por ter me indicado o norte em vários momentos desta pesquisa.

Ao grupo de pesquisa *Machine Vision and Pattern Recognition Research Group* da *Lappeenranta University of Technology* (Finlândia), pelo provimento do banco de imagens DIARETDB1, como também agradeço à acadêmica da UNIPAMPA, Luiza Bagesteiro, pela disponibilização do *ground-truth* aprimorado deste banco.

Aos meus colegas do NTIC e do PPGEE pelo apoio e incentivo durante o curso.

Por fim, à UNIPAMPA, pela concessão de horário especial para estudo e acompanhamento das disciplinas do curso de mestrado.

“Don't keep forever on the public road, going only where others have gone. Leave the beaten track occasionally and dive into the woods. You will be certain to find something you have never seen before. Of course it will be a little thing, but do not ignore it. Follow it up, explore around it; one discovery will lead to another, and before you know it you will have something worth thinking about to occupy your mind. All really big discoveries are the result of thought.”

Alexander Graham Bell

RESUMO

Este trabalho tem como objetivo a proposição de um novo método para a detecção automática de microaneurismas e hemorragias em imagens de fundo do olho. Essas lesões são consideradas o primeiro sinal de retinopatia diabética. A retinopatia diabética é uma doença originada pelo diabetes e é apontada com a principal causa de cegueira na população com idade ativa de trabalho. O método proposto é fundamentado em conceitos de morfologia matemática e consiste em eliminar os componentes da anatomia da retina até atingir o conjunto de lesões. Este método é formado por cinco etapas: a) pré-processamento; b) destaque das estruturas escuras; c) detecção dos vasos sanguíneos; d) eliminação dos vasos sanguíneos; e) eliminação da fóvea. A precisão do método foi testada num banco de dados público de imagens de fundo do olho, onde o mesmo obteve resultados satisfatórios e comparáveis aos demais métodos da literatura, reportando médias de sensibilidade e especificidade de 87.69% e 92.44%, respectivamente.

Palavras-chave: processamento de imagens, morfologia matemática, imagens de fundo do olho, microaneurismas, hemorragias.

ABSTRACT

This contribution presents an approach for automatic detection of microaneurysms and hemorrhages in fundus images. These lesions are considered the earliest signs of diabetic retinopathy. The diabetic retinopathy is a disease caused by diabetes and is considered as the major cause of blindness in working age population. The proposed method is based on mathematical morphology and consists in removing components of retinal anatomy to reach the lesions. This method consists of five steps: a) pre-processing; b) enhancement of low intensity structures; c) detection of blood vessels; d) elimination of blood vessels; e) elimination of the fovea. The accuracy of the method was tested on a public database of fundus images, where it achieved satisfactory results, comparable to other methods from the literature, reporting 87.69% and 92.44% of mean sensitivity and specificity, respectively.

Keywords: image processing, mathematical morphology, fundus images, microaneurysms, hemorrhages.

LISTA DE FIGURAS

Figura 1.1 – Retinografia colorida	12
Figura 1.2 – Retinografia fluorescente	13
Figura 1.3 – Lesões vermelhas em uma imagem de fundo do olho	14
Figura 1.4 – Simulação de RD em estágio avançado	18
Figura 1.5 – Detecção manual de microaneurismas e hemorragias	19
Figura 1.6 – Diferentes estruturas presentes na retina	20
Figura 3.1 – Elementos estruturantes típicos	33
Figura 3.2 – Dilatação e erosão de uma imagem de fundo do olho	38
Figura 3.3 – Abertura e fechamento de uma imagem de fundo do olho.....	39
Figura 3.4 – Operadores baseados em reconstrução morfológica.....	43
Figura 3.5 – Operador <i>FILL</i>	44
Figura 4.1 – <i>Ground-truth</i> do DIARETDB1	46
Figura 4.2 – <i>Ground-truth</i> modificado.....	47
Figura 4.3 – Comparação dos três canais RGB	48
Figura 4.4 – Pré-processamento da imagem	49
Figura 4.5 – Destaque das estruturas escuras da imagem	51
Figura 4.6 – Detecção dos vasos sanguíneos.....	53
Figura 4.7 – Eliminação dos vasos sanguíneos	54
Figura 4.8 – Eliminação da fóvea	56
Figura 4.9 – Fluxograma do método de detecção	57
Figura 5.1 – Ilustração dos falsos positivos/negativos e dos verdadeiros positivos/negativos	61
Figura 5.2 – Exemplo de uma imagem de saída do método de detecção.....	64
Figura 5.3 – Problemas na eliminação dos vasos sanguíneos.....	64
Figura 5.4 – Problemas na eliminação da região da fóvea	65
Figura 5.5 – Problemas na identificação de lesões pequenas	66
Figura 5.6 – Problemas com diferenças de iluminação	67
Figura 5.7 – Classificações de curvas ROC	68
Figura 5.8 – Curva ROC.....	69

LISTA DE TABELAS

Tabela 1.1 – Trabalhos relacionados	15
Tabela 1.2 – Escala internacional de gravidades da retinopatia diabética	17
Tabela 5.1 – Média dos valores de VP, FN, FP e VN	60
Tabela 5.2 – Resultados do método de detecção proposto	62
Tabela 5.3 – Comparativo entre os trabalhos relacionados	62
Tabela 5.4 – Pontos de corte para a curva ROC.....	69
Tabela 5.5 – Tempo médio de processamento por imagem	70

LISTA DE ABREVIATURAS E SIGLAS

CLAHE – *Contrast Limited Adaptive Histogram Equalization*

FN – Falso Negativo

FP – Falso Positivo

FSA – Filtros Sequenciais Alternados

OMS – Organização Mundial da Saúde

RD – Retinopatia Diabética

RDNP – Retinopatia Diabética Não-Proliferativa

RDP – Retinopatia Diabética Proliferativa

ROC – *Receiver Operating Characteristic*

VN – Verdadeiro Negativo

VP – Verdadeiro Positivo

LISTA DE SÍMBOLOS

δ – Dilatação Morfológica

ε – Erosão Morfológica

ρ_B – Gradiente Morfológico

γ – Abertura Morfológica

\emptyset – Fechamento Morfológico

γ^{TH} – Top-hat por abertura

\emptyset^{TH} – Top-hat por fechamento

k^{TH} – Realce de contraste de Soille

$R_g(f)$ – Reconstrução morfológica por dilatação da imagem marca f condicionada à imagem máscara g

$R_g^*(f)$ – 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 -máxima

$Hmin$ – Filtro H -mínima

$FILL$ – Operador para fechamento de buracos

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Motivação	16
1.2	Objetivos	21
1.3	Organização do documento	21
2	TRABALHOS RELACIONADOS	22
2.1	Estado da arte dos métodos de detecção de microaneurismas e hemorragias.....	22
2.2	Conclusão	29
3	MORFOLOGIA MATEMÁTICA.....	32
3.1	Conceitos básicos.....	32
3.2	Operadores e transformações fundamentais de morfologia matemática em tons de cinza	33
3.3	Reconstrução morfológica	40
4	MATERIAIS E MÉTODOS	45
4.1	Materiais para detecção de microaneurismas e hemorragias.....	45
4.2	Método para detecção de microaneurismas e hemorragias	47
4.2.1	Pré-processamento da imagem	48
4.2.2	Destaque das estruturas escuras da imagem	49
4.2.3	Detecção dos vasos sanguíneos	51
4.2.4	Eliminação dos vasos sanguíneos	54
4.2.5	Eliminação da fóvea	54
4.2.6	Fluxograma do método.....	56
4.3	Conclusão	57
5	DISCUSSÃO E RESULTADOS EXPERIMENTAIS	59
5.1	Medidas utilizadas para quantificação dos resultados.....	59
5.2	Resultados alcançados pelo método de detecção.....	60
6	CONCLUSÃO	71
	REFERÊNCIAS.....	73
	APÊNDICE A – Resultados da detecção em imagens com lesões	77
	APÊNDICE B – Resultados da detecção em imagens sem lesões	78

1 INTRODUÇÃO

A Retinopatia Diabética (RD) é uma doença sistêmica originada pelo diabetes e que se manifesta na retina do olho humano. A RD é uma das mais sérias e mais frequentes doenças que acometem o olho, sendo considerada a causa mais comum de cegueira em adultos entre 20 e 60 anos de idade (WALTER et al., 2007). A detecção precoce e a triagem periódica da RD através da análise de imagens de fundo do olho ajudam a reduzir a progressão desta doença e a prevenir a subsequente perda da capacidade visual (SALEH & ESWARAN, 2012).


Imagens de fundo do olho são capturadas através de um exame denominado retinografia, o qual pode ser realizado de duas formas: retinografia colorida e retinografia fluorescente. A retinografia colorida (ou simples) é uma técnica não invasiva que consiste na fotografia do fundo do olho, permitindo a documentação de alterações na retina e no nervo óptico (LOTTEN EYES, 2013). A retinografia fluorescente é uma técnica invasiva, que consiste na introdução na corrente sanguínea de um corante fluorescente, a fluoresceína sódica, que, ao circular pelos vasos sanguíneos da retina, permite o estudo da dinâmica circulatória e a sua documentação através de fotos ou vídeos (IOFS, 2013). A Figura 1.1 mostra uma retinografia colorida, retirada de um banco de dados público de imagens de fundo do olho (KAUPPI et al., 2007). A Figura 1.2 mostra uma retinografia fluorescente (BABA et al., 1999).

Figura 1.1 - Retinografia colorida



Fonte: KAUPPI et al., 2007.

Figura 1.2 – Retinografia fluorescente



Fonte: BABA et al., 1999.

A retinografia fluorescente destaca melhor as estruturas da retina, uma vez que possui um contraste maior do que a retinografia colorida (NIEMEIJER et al., 2005). No entanto, a retinografia fluorescente mostra-se inviável para triagem em massa de populações para identificação de RD, uma vez que pode causar efeitos colaterais, tais como náuseas e vômitos. Uma taxa de mortalidade de 1 para 222.000 associada ao uso intravenoso de fluorescência proíbe a aplicação desta técnica para propósitos de triagem em larga escala (NIEMEIJER et al., 2005). Portanto, a retinografia colorida mostra-se mais adequada para uso em sistemas de detecção automática de RD. De fato, publicações atuais na área, que serão explanadas nos capítulos seguintes, têm-se concentrado em imagens captadas de forma não invasiva.

O aparecimento de lesões vermelhas na parede dos vasos sanguíneos da retina é considerado o primeiro sinal de RD (JAAFAR et al., 2011). Estas lesões vermelhas podem ser classificadas de duas formas: microaneurismas e hemorragias (DEVARAJ & NAGAVEENA, 2013).

Os microaneurismas podem causar o estreitamento e às vezes o bloqueio dos vasos sanguíneos da retina, além do enfraquecimento de sua parede, sendo que estes microaneurismas muitas vezes se rompem, causando hemorragias e infiltração de gordura na retina (ALBUQUERQUE, 2013). Na Figura 1.3 é mostrada uma imagem de fundo do olho com lesões vermelhas. As hemorragias apresentam-

se como inchaços de cor vermelha, destacadas na área circulada; mais abaixo, um microaneurisma é apresentado como um pequeno ponto vermelho, destacado por uma seta.

Figura 1.3 – Lesões vermelhas em uma imagem de fundo do olho



Publicações atuais na área têm demonstrado resultados satisfatórios ao utilizar-se de técnicas de morfologia matemática para a extração dos diferentes objetos presentes na anatomia da retina a fim de detectar as lesões vermelhas, conforme será visto em detalhes nos capítulos seguintes. A Tabela 1.1 sumariza estas publicações com as principais características de cada uma.

Tabela 1.1 - Trabalhos relacionados

Trabalho	Características Principais	Imagens públicas?
Jaafar et al. (2011)	Utiliza técnicas morfológicas para segmentar as regiões candidatas a lesões e posteriormente aplica um classificador baseado em regras para identificar as lesões reais.	Sim: DIARETDB0 e DIARETDB1
Niemeijer et al. (2005)	Tem como principal contribuição um novo sistema para detecção de regiões candidatas baseando-se em classificação de pixels.	Não
Ravishankar et al. (2009)	Detecta o disco óptico pela intersecção dos principais vasos sanguíneos da retina e utiliza operadores morfológicos para detecção das lesões vermelhas e demais objetos.	Algumas: DIARETDB0, DRIVE e STARE
Balasubramanian et al. (2008)	Extrai as regiões as candidatas a lesões vermelhas com um método denominado <i>Automatic Seed Generation</i> , baseado na intensidade do pixel e sua similaridade com a vizinhança.	Não especificado
Badea et al. (2008)	Detecta todos os objetos da retina com um método proposto, denominado <i>Expanding Gradient Method</i> , e posteriormente extrai as regiões candidatas a lesões.	Não especificado
Kande et al. (2010)	Utiliza operadores da morfologia matemática para extração de regiões candidatas e posteriormente propõe um classificador baseado em máquinas de vetores de suporte.	Algumas: STARE, DIARETDB0 e DIARETDB1
Shahin et al. (2012)	Utiliza operadores da morfologia matemática para a extração dos diferentes objetos da retina e posteriormente aplica um classificador baseado em redes neurais artificiais.	Sim: STARE, DRIVE, DIARETDB0 e DIARETDB1
Roychowdhury et al. (2012)	Tem como principal contribuição um método para detecção do disco óptico denominado <i>Minimum Intensity Maximum Solidity</i> .	Sim: DIARETDB1
Garcia et al. (2008)	Utiliza um classificador de regiões candidatas baseado em redes neurais artificiais do tipo <i>Multilayer Perceptron</i> .	Não
Hatanaka et al. (2008)	Apresenta um classificador de regiões candidatas que realiza cálculos utilizando os três canais do espaço de cores HSV (<i>Hue Saturation Value</i>).	Não
Esmaeili et al. (2010)	Realiza a extração de regiões candidatas a lesões vermelhas utilizando a transformada <i>curvel</i> .	Sim: DIARETDB1
Mariño et al. (2008)	Realiza a extração de regiões candidatas com a combinação de diferentes filtros, e posteriormente executa um algoritmo de refinamento baseado no crescimento de regiões candidatas.	Não

Dentro deste contexto, o objetivo deste trabalho é introduzido, o qual propõe um novo método para detecção automatizada de lesões vermelhas em imagens de fundo do olho, utilizando imagens captadas de uma forma não invasiva. As imagens utilizadas pelo método proposto nesta pesquisa foram provenientes do banco de dados público de imagens de fundo do olho DIARETDB1 (KAUPPI et al., 2007). O

método também foi concebido baseando-se em técnicas de morfologia matemática, e seus resultados foram quantificados utilizando medidas de sensibilidade e especificidade (o conceito destas medidas é definido na seção 5.1), e, posteriormente, tais resultados foram comparados aos resultados alcançados por outros métodos de detecção de lesões vermelhas presentes na literatura.

Este capítulo apresenta na seção 1.1 a motivação para a realização desta pesquisa; na seção 1.2 são apresentados os objetivos deste trabalho; e na seção 1.3, por fim, é realizada uma breve explanação dos demais capítulos desta dissertação.

1.1 Motivação

A Organização Mundial da Saúde (OMS) estima que atualmente existam 347 milhões de pessoas no mundo que sofrem de diabetes e projeta que esta doença será a sétima causa de morte no mundo no ano de 2030 (WORLD HEALTH ORGANIZATION; INTERNATIONAL DIABETES FEDERATION, 2013). O diabetes está associado a altas taxas de trabalho perdido, incapacidade e morte prematura, sendo que o prejuízo para a economia dos EUA só no ano de 2002 foi estimado em 40 bilhões de dólares (AMERICAN DIABETES ASSOCIATION, 2003).

A RD, que é uma doença oriunda do diabetes, pode ser considerada atualmente a principal causa de cegueira em adultos na faixa etária de 20 a 74 anos (AMERICAN DIABETES ASSOCIATION, 2004), afetando assim principalmente pessoas em idade ativa de trabalho. Estima-se que o governo dos EUA tenha um custo anual de 500 milhões de dólares no tratamento de deficiências visuais originadas pelo diabetes (SALEH & ESWARAN, 2012).

Estudos apontam que pessoas com idade superior a 30 anos e que sofrem de diabetes por mais de 15 anos tenham 78% de chances de também possuírem RD. Este número sobe para 97% no caso de pessoas com menos de 30 anos de idade com diabetes por igual período de tempo (SUJITHKUMAR et al., 2012).

A RD é silenciosa nos seus estágios iniciais, isto é, muitos pacientes que sofrem de diabetes não são cientes de sua presença, e permanecem não diagnosticados até que alguma deficiência visual grave ocorra (WALTER et al., 2007). Portanto, a realização de exames anuais em todos pacientes diabéticos é altamente recomendada (LEE et al, 2001). O problema, contudo, é que isso

acarretaria num custo muito elevado, pois a quantidade de exames é enorme, além do fato de não existirem especialistas o bastante para realizarem tantos exames (WALTER et al., 2007). Assim, neste processo de triagem, o qual consiste em separar as retinas normais das que manifestam lesões, um sistema de identificação automatizada de lesões vermelhas torna-se necessário.

Conforme observa Bagesteiro (2013), a RD é uma doença progressiva que apresenta as seguintes etapas: RD não aparente, RD não-proliferativa (RDNP), e RD proliferativa (RDP). Na Tabela 1.2 é apresentada uma escala internacional de gravidades da RD, e o que caracteriza cada nível de gravidade (CIULLA; AMADOR; ZINMAN, 2003).

Tabela 1.2 - Escala internacional de gravidades da retinopatia diabética

Nível de Gravidade	Características
RD 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)

Conforme pode ser visto na Tabela 1.2, os microaneurismas são presentes nos estágios iniciais da RD (leve e moderada), caracterizando o início da doença. As hemorragias, por sua vez, são presentes nos estágios mais avançados (RDNP grave e RDP). No estágio mais avançado da doença (RDP), os sinais não são enviados pela retina para o cérebro devido à falta de fornecimento de sangue e isto provoca o aparecimento de novos vasos sanguíneos na retina (SUJITHKUMAR & SINGH, 2012). Na Figura 1.4 é mostrada em (a) a visão a partir de uma retina normal e em (b) a visão de uma pessoa em estágio avançado de RD (SHAHIN et al., 2012).


Figura 1.4 – Simulação de RD em estágio avançado




(a) visão a partir de uma retina normal; (b) visão de uma pessoa com RD em estágio avançado da doença. Fonte: Shahin et al., 2012.

Detectar as lesões vermelhas presentes na retina 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 (BAGESTEIRO, 2013). A Figura 1.5 (a) mostra uma imagem de fundo do olho com microaneurismas e hemorragias. A Figura 1.5 (b) mostra a mesma imagem, mas com as áreas lesionadas delimitadas por especialistas em oftalmologia.

Figura 1.5 – Detecção manual de microaneurismas e hemorragias



(a)




(b)

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

No entanto, detectar manualmente as lesões vermelhas é um processo demorado e suscetível a erros, mesmo para um especialista treinado (JAAFAR et al., 2011). Dessa forma, evidencia-se a necessidade de um sistema para detecção automatizada de lesões vermelhas em imagens de fundo do olho. Contudo, microaneurismas e hemorragias podem ser considerados de difícil detecção por vários motivos. 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). Além disso, microaneurismas geralmente possuem um diâmetro inferior a 125 μm , sendo

que este tamanho pequeno e as variações de intensidade no *background* tornam a detecção de microaneurismas uma tarefa problemática e complicada (SALEH & ESWARAN, 2012). Conforme observado por Walter et al. (2007), as imagens de fundo do olho frequentemente sofrem de variações de iluminação, contraste pobre e ruído, necessitando assim passar por etapas de pré-processamento. Segundo Kande et al. (2010) os maiores desafios para a detecção de lesões vermelhas são a segmentação dos microaneurismas nas áreas de baixo contraste da imagem e a presença de lesões brancas na retina (exsudatos). Pode-se mencionar ainda que microaneurismas e hemorragias possuem vários tamanhos e formas, sendo difícil realizar a detecção de todos eles na imagem, 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 1.6 ilustra as estruturas normais presentes na retina juntamente com as lesões brancas (exsudatos).

Figura 1.6 – Diferentes estruturas presentes na retina



1.2 Objetivos

O objetivo geral deste trabalho consiste na proposição de um novo método para a detecção automática de microaneurismas e hemorragias em imagens de fundo do olho. Entre os objetivos específicos, podem-se citar:

- Observar o estágio atual da literatura quanto à detecção de microaneurismas e hemorragias em imagens de fundo do olho;
- Utilizar técnicas de processamento de imagens para a concepção do método de detecção;
- Utilizar o banco de dados público de imagens de fundo do olho DIARETDB1 (KAUPPI et al., 2007);
- Analisar a precisão do método através das medidas de sensibilidade e especificidade;
- Comparar os resultados obtidos pelo método com os resultados alcançados pelos trabalhos estudados a fim de obter resultados iguais ou superiores.

1.3 Organização do documento

Este documento está organizado da seguinte forma:

Capítulo 2: Apresenta trabalhos da literatura atual relacionados à detecção de microaneurismas e hemorragias em imagens de fundo do olho e posteriormente destaca pontos em comum entre essas publicações.

Capítulo 3: Descreve conceitos fundamentais de morfologia matemática, os quais foram utilizados na concepção do método de detecção proposto por este trabalho.

Capítulo 4: Descreve os materiais utilizados por esta pesquisa e o funcionamento do método de detecção de microaneurismas e hemorragias proposto.

Capítulo 5: Discute e apresenta os resultados alcançados pelo método proposto.

Capítulo 6: Apresenta a conclusão e as atividades futuras deste trabalho.

2 TRABALHOS RELACIONADOS

Neste capítulo é apresentada uma revisão do estado da arte de métodos de detecção de lesões vermelhas em imagens de fundo do olho. A literatura fornece diversos trabalhos relacionados ao tema, nos quais os autores fornecem soluções distintas para o problema em questão. O objetivo desta seção, portanto, é investigar os métodos já existentes, descrevendo as abordagens e procedimentos utilizados por cada autor, identificando assim características em comum. Este capítulo ainda tem como objetivos levantar a fonte provedora das imagens de cada trabalho (bases de dados públicas ou de acesso privado) e verificar os resultados alcançados.

Na seção 2.1 são apresentadas publicações atuais da área, com uma breve descrição do método proposto e os resultados obtidos; Na seção 2.2, por fim, é realizado o fechamento do capítulo.

2.1 Estado da arte dos métodos de detecção de microaneurismas e hemorragias

O artigo de Jaafar et al. (2011) propõe um método para detecção automatizada de lesões vermelhas utilizando morfologia matemática. Inicialmente, é realizado um pré-processamento, o qual envolve a extração do canal verde do espaço de cores RGB (o qual possui um melhor contraste) e a redução de diferenças de iluminação através de correções de sombra (utilizando um filtro de medianas). Após o pré-processamento, o método é implementado em quatro fases, a saber: 1) extração de regiões candidatas; 2) extração de características; 3) detecção de vasos sanguíneos; e 4) classificação. Na primeira fase é executada uma operação no *background* (fundo da imagem) denominada *flood-fill*. Após, a imagem pré-processada é subtraída da imagem que sofreu o *flood-fill*, gerando uma imagem resultante. Logo após, essa imagem é binarizada através de um método de limiarização adaptativo. Na segunda fase, isto é, na extração de características, é realizada uma série de cálculos, tais como o de circularidade, o de área, o de perímetro e o de desvio padrão, a fim de categorizar as regiões candidatas. Na terceira fase, os vasos sanguíneos são removidos baseando-se no operador morfológico de fechamento. Na quarta e última fase, é realizada a classificação das regiões candidatas (a fim de separar lesões reais de outras estruturas), através de um classificador baseado em regras, utilizando-se dos resultados obtidos na

segunda fase do método. O método utilizou 219 imagens de diferentes bancos de dados, sendo 130 destas provenientes do banco DIARETDB0 e 89 do banco DIARETDB1, e obteve sensibilidade de 89,7% e especificidade de 98,6%. A principal limitação do método foi a não detecção das lesões vermelhas presentes dentro da fóvea.

No trabalho de Niemeijer et al. (2005) é proposta uma abordagem híbrida para a detecção de lesões vermelhas. O método deste artigo se apresenta útil na fase de pré-triagem de um conjunto de imagens de fundo do olho, onde o foco desta fase é a identificação de imagens com incidências de lesões, e não as lesões em si. O método proposto é baseado em três estágios. No primeiro estágio é realizado um pré-processamento da imagem, onde é extraído o canal verde do espaço de cores RGB e é executado um filtro de medianas a fim de remover variações de iluminação. Também neste estágio são removidas as lesões brancas (por exemplo, os exsudatos duros e algodinosos), a fim de evitar falsos positivos nas fases seguintes. No segundo estágio, as regiões candidatas são extraídas aplicando conceitos de morfologia matemática através da transformada *top-hat*. Nesta operação utilizaram-se elementos estruturantes com diferentes ângulos de inclinação e de comprimento maior que as regiões lesionadas, a fim de separar as lesões vermelhas dos vasos sanguíneos. Ainda no segundo estágio, um método de extração de candidatos baseado em classificação de pixels é proposto e posteriormente seu resultado é combinado com a solução *top-hat*, aumentando-se o número de verdadeiros-positivos. No terceiro e último estágio um sistema de classificação de candidatos é proposto, a fim de identificar as reais lesões dentre as candidatas. Tal sistema considera a extração de diferentes características dos objetos candidatos, no que diz respeito à forma do objeto e à intensidade de cada pixel. O método foi testado num conjunto de 100 imagens não públicas, onde apresentou sensibilidade de 100% e especificidade de 87%. Apesar dos resultados satisfatórios, o autor relata que o método possui um tempo de processamento elevado, levando 15 minutos na análise de cada imagem.

Em Ravishankar et al. (2009) é proposto um novo método para extração de características em imagens de fundo do olho, o qual se baseia em quatro etapas. Na primeira etapa o autor apresenta um algoritmo para extração dos vasos sanguíneos baseado na operação de fechamento morfológico. Na sequência, extrai-se o canal verde do espaço de cores RGB, e executa-se o operador de fechamento morfológico

na imagem. Nesta operação, utilizou-se um elemento estruturante em formato de disco com um raio de espessura aproximada ao vaso sanguíneo mais grosso. Após, o fechamento morfológico é executado novamente, mas com um disco de raio menor, e por último subtraem-se essas duas imagens, resultando nos vasos sanguíneos extraídos. Ainda nesta etapa, a imagem é binarizada e é então executado um filtro de medianas a fim de remover ruídos. Na segunda etapa, os exsudatos (lesões mais claras) são localizados utilizando detecção de bordas com operações morfológicas. Na terceira etapa ocorre a detecção do disco óptico, baseando-se nos vasos sanguíneos mais grossos que saem do disco e também na intensidade de cor do disco. Na quarta e última etapa, as lesões vermelhas são detectadas utilizando reconstrução morfológica e a fóvea é removida baseando-se na localização do disco óptico e na curvatura dos vasos sanguíneos principais. O método foi testado num conjunto de 516 imagens, utilizando diferentes bancos de dados (tais como DIARETDB0, DRIVE e STARE) e também imagens de hospitais, obtendo uma sensibilidade média de 95,1% e uma especificidade média de 90.5% na detecção de lesões vermelhas.

O artigo de Balasubramanian et al. (2008) propõe um novo método para detecção de lesões vermelhas em imagens de fundo do olho. Primeiramente, o autor realiza um pré-processamento da imagem, extraindo o canal verde do espaço de cores RGB, e aplica uma correção de sombra com um filtro de medianas. Posteriormente, inicia-se a fase de extração das regiões candidatas, com um algoritmo denominado *Automatic Seed Generation* (ASG). Neste algoritmo, um pixel é definido como candidato se sua intensidade está no *foreground* (primeiro plano da imagem) e se é similar aos seus vizinhos, através do cálculo de uma medida de similaridade numa vizinhança de tamanho 3x3. Se o valor da similaridade for maior que um determinado *threshold*, o pixel é definido como candidato. Após, os vasos sanguíneos são eliminados ao remover-se todas as regiões candidatas que possuem um valor de diâmetro maior que um outro *threshold*. Na fase seguinte do método, ocorre a classificação das regiões candidatas com um algoritmo chamado *Spatio Temporal Feature Map* (STFM). O método foi testado num conjunto de 63 imagens (de origem não divulgada), atingindo 87% de sensibilidade e 95% de especificidade. Embora o método tenha alcançado resultados interessantes, as áreas lesionadas nas imagens testadas foram delimitadas por apenas um especialista em oftalmologia, o que torna esses resultados questionáveis, uma vez

que o processo de identificação manual é suscetível a erros, devido ao tamanho quase imperceptível de algumas lesões vermelhas.

No trabalho de Badea et al. (2008) as lesões vermelhas em imagens de fundo do olho são detectadas utilizando um método baseado em quatro passos. No primeiro passo a imagem é pré-processada, extraíndo-se o canal verde do espaço de cores RGB. Após, a imagem é suavizada, amenizando-se o ruído (provocado pelas diferenças de iluminação) através de um filtro de médias. Este filtro é executado apenas nos pixels com altas diferenças de cor de dentro de sua vizinhança. Ainda neste passo, é executado um filtro de medianas em toda imagem, com a imagem resultante subtraída da imagem suavizada. No segundo passo o objetivo é detectar todos os objetos da imagem. Realiza-se uma detecção de bordas, utilizando o método proposto pelo artigo, denominado *Expanding Gradient Method* (EGM), baseado na repetição do cálculo do gradiente de intensidade. Logo após, a imagem é binarizada. No terceiro passo os vasos sanguíneos, as lesões brancas e o disco ótico são eliminados, deixando apenas as lesões vermelhas, como regiões candidatas. No quarto e último passo, as regiões candidatas são definidas como lesões com base na análise do histograma de frequências de cada região, onde um pico mais elevado na parte esquerda do histograma define a região como lesão vermelha. O método foi testado num conjunto de 47 imagens (de origem não divulgada), obtendo uma precisão de 85% na detecção de lesões vermelhas, sem mencionar medidas de especificidade e sensibilidade. Das 47 imagens testadas, 44 eram de retinas com lesões vermelhas (de diferentes posições, tamanhos e formas), variando de uma a 69 lesões por imagem, as quais foram delimitadas por especialistas em oftalmologia.

Em Kande et al. (2010) é proposto um método baseado em três estágios. No primeiro estágio é realizado um pré-processamento na imagem, extraíndo além do canal verde do espaço de cores RGB, também o canal vermelho deste espaço, e unindo-se seus dois histogramas de frequências, resultando num alto contraste entre as lesões vermelhas e o *background*, e um baixo contraste entre as lesões brancas e o *background*. Logo após, é passado um filtro de medianas a fim de remover diferenças de iluminação. No segundo estágio é realizada a detecção de regiões candidatas, inicialmente definindo-se um protótipo de filtro para destacar as regiões vermelhas. Após, para transformar a imagem para o formato binário, é executado um algoritmo de *threshold* otimizado, que leva em conta a distribuição espacial dos

níveis de cinza ao longo da imagem. Ainda neste estágio é executada a transformada *top-hat* (com elementos estruturantes lineares de diferentes ângulos), subtraindo a imagem resultante da imagem que sofreu o *thresholding*, a fim de remover os vasos sanguíneos. No terceiro e último estágio, as regiões candidatas são classificadas utilizando máquinas de vetores de suporte. O método foi testado em 35 imagens, selecionadas aleatoriamente, dos bancos DIARETDB0, DIARETDB1 e STARE e em 54 imagens providas por um hospital, obtendo medidas de sensibilidade e especificidade de 100% e 91%, respectivamente.

No método proposto no artigo de Shahin et al. (2012), a imagem é pré-processada primeiramente executando-se um algoritmo de melhoramento de imagens de baixa nitidez, que é baseado num filtro para remoção de ruídos. Após, é extraído o canal verde do espaço de cores RGB e executa-se uma equalização de histograma por regiões, a fim de melhorar o contraste. Concluído o pré-processamento, é executada a operação de abertura morfológica para destacar os vasos sanguíneos. Após, o disco óptico é removido ao subtrair-se a imagem pré-processada da imagem resultante da abertura morfológica, permanecendo na imagem apenas os vasos sanguíneos. No passo seguinte, os microaneurismas são identificados num procedimento independente: da mesma forma que os vasos, realiza-se a equalização de histograma por regiões sobre o canal verde do espaço de cores RGB. Logo após, é passado um detector de bordas com o método de *Canny*. Na sequência, é executada uma abertura morfológica e a imagem com bordas detectadas é extraída desta imagem. No passo seguinte, a imagem com os vasos sanguíneos é subtraída da imagem calculada anteriormente, resultando, finalmente, nos microaneurismas. O artigo também apresenta classificador baseado em redes neurais, o qual informa se a imagem de entrada é de uma retina normal ou de uma retina lesionada. O método foi testado num conjunto de 340 imagens, provenientes de quatro bancos de dados públicos: STARE, DRIVE, DIRECTDB0 e DIRECTDB1, obtendo 88% de sensibilidade e 100% de especificidade.

No artigo de Roychowdhury et al. (2012) é apresentado um novo método para detecção de RD em imagens de fundo do olho. O primeiro passo do método é o pré-processamento, onde é extraído o canal verde do espaço de cores RGB e é executada uma equalização de histograma. Após, cada imagem é redimensionada para um tamanho padrão. Logo após, o disco óptico é detectado utilizando um algoritmo proposto, denominado *Minimum Intensity Maximum Solidity (MinIMaS)*.

Este algoritmo é uma das principais contribuições do artigo, uma vez que o mesmo considera tanto as variações de iluminação sobre o disco como também sua exibição parcial, como ocorre em algumas imagens, atingindo assim, altos níveis de precisão. Posteriormente é executada uma correção de sombra sobre a imagem pré-processada com um filtro de medianas, e a seguir os vasos sanguíneos são detectados. Logo após, as lesões brancas são detectadas sobre a imagem pré-processada utilizando-se erosão e reconstrução morfológica. A detecção das lesões vermelhas ocorre por eliminação, ao subtrair-se as imagens do disco e dos vasos sanguíneos da imagem com correção de sombra. Após, é executado um classificador sobre as regiões candidatas, denominado *Gaussian mixture models (GMM)*, a fim de rejeitar os falsos positivos, atingindo 75.5% de sensibilidade e 93.73% de especificidade na detecção de lesões vermelhas ao considerar as imagens do banco DIARETDB1.

Em Garcia et al. (2008) é apresentado um método para detecção de lesões vermelhas com um classificador baseado em redes neurais do tipo *Multilayer Perceptron (MLP)*. Este método é baseado em cinco etapas. Na primeira etapa é realizado o pré-processamento, extraíndo-se o canal verde do espaço de cores RGB e executando-se uma normalização de contraste. Na segunda etapa é realizada uma segmentação na imagem, extraíndo-se as regiões candidatas, baseando-se no valor de intensidade do pixel em relação à sua vizinhança. Na terceira etapa, é realizada a extração de características das regiões candidatas, tais como circularidade, largura/altura da região, comprimentos de borda, médias, entre outros. Na quarta etapa é realizada uma seleção das características mais úteis utilizando-se regressão logística binária, um método estatístico que analisa o relacionamento entre as diferentes variáveis extraídas no passo anterior. Na quinta e última etapa, o classificador baseado em redes neurais é acionado, identificando ou não a região candidata como lesão vermelha. O método utilizou um conjunto de 100 imagens de um instituto de oftalmobiologia espanhol, sendo 50 imagens para treinar a rede neural e as outras 50 para testar o desempenho do método. O mesmo obteve sensibilidade e especificidade de 100% e 60%, respectivamente. Apesar de relatar uma medida de 100% de sensibilidade, o autor menciona que o algoritmo proposto apresenta algumas limitações, não detectando lesões vermelhas muito sutis, devido às variadas características de tamanho e cor dessas estruturas. O método também não detectou as lesões muito próximas ou conectadas aos vasos sanguíneos.

No trabalho de Hatanaka et al. (2008) é proposto um novo método para detecção de lesões vermelhas, no qual o autor o organizou em seis etapas. Na primeira etapa realizou-se a obtenção das imagens através de uma câmera de fundo de olho e a delimitação das áreas lesionadas por um oftalmologista. Na segunda etapa foi realizado o pré-processamento das imagens, com uma correção de iluminação nos três canais, manipulando o espaço de cores HSV (*Hue Saturation Value*) e, logo após, uma equalização de histograma. Na terceira etapa é realizada a detecção do disco óptico, com um método de *thresholding*. Na quarta etapa as regiões candidatas são identificadas baseando-se na intensidade de seus pixels e os vasos sanguíneos são eliminados. Na quinta etapa ocorre uma eliminação de falsos positivos os quais estavam conectados aos vasos sanguíneos, baseando-se na relação altura-largura da região. Na sexta e última etapa, mais falsos positivos são eliminados pela análise de características das regiões, utilizando um classificador baseado em regras o qual extrai 15 características de cada região, dentre as quais a média dos valores dos pixels, a variância, o contraste, entre outros, sendo que estes 15 cálculos são aplicados nos três canais da imagem, totalizando 45 medidas por região. O método foi avaliado num conjunto de 125 imagens obtidas de um hospital local, obtendo um resultado de 80% tanto para sensibilidade quanto para especificidade. O método apresentou uma limitação ao não detectar as lesões que estavam conectadas aos vasos sanguíneos, desconsiderando 20% do total de hemorragias.

Em Esmaili et al. (2010) é proposto um novo método para detecção de lesões vermelhas baseado na transformada *curvelet*, o qual pode ser explicado em quatro etapas. Na primeira etapa do método é realizado um pré-processamento nas imagens, extraíndo-se o canal verde do espaço de cores RGB e corrigindo-se variações de iluminação através de um algoritmo de equalização proposto, alterando cada pixel através de uma fórmula envolvendo a intensidade máxima e média em uma janela 10x10. A passagem dessa equalização tende a tornar o *background* da imagem mais uniforme. Na segunda etapa, é realizada a extração das regiões candidatas utilizando-se a transformada *curvelet*, onde seus coeficientes são configurados para retornar apenas os objetos mais escuros da imagem, ou seja, as lesões vermelhas e os vasos sanguíneos. Na terceira etapa, os vasos sanguíneos são extraídos com a transformada *curvelet* e uma filtragem de objetos pelo seu comprimento e raio, descartando assim as regiões muito pequenas. Na quarta e

última etapa, a imagem obtida na terceira etapa (com os vasos) é subtraída da imagem obtida na segunda etapa (com as regiões candidatas), restando assim somente as lesões vermelhas. O método foi testado num conjunto de 89 imagens, providas pelo banco de dados DIARETDB1, obtendo sensibilidade e especificidade de 94% e 87%, respectivamente.

Em Mariño et al. (2008) é proposto um novo método para a detecção automatizada de lesões vermelhas, o qual é baseado em três estágios. No primeiro estágio, após a extração do canal verde do espaço de cores RGB, as regiões candidatas são identificadas, executando-se três filtros, os quais consideram a forma circular e a intensidade escura das lesões vermelhas. Logo após, os resultados dos três filtros são combinados numa única imagem, contendo as regiões candidatas. No segundo estágio é proposto um algoritmo de refinamento, a fim de eliminar falsos positivos, o qual é baseado no crescimento de regiões a partir de sementes: uma semente é definida como um ponto onde houve alto nível de correlação no resultado dos três filtros do primeiro estágio; uma vez identificada uma semente, é calculado um *threshold* para o processo de crescimento da mesma, o qual atuará como limitante do crescimento; após, o algoritmo começa o crescimento da semente e só para quando não houver mais pixels conectados de valor menor ao *threshold* calculado. Assim, regiões acima de 200 pixels de área são descartadas, uma vez que correspondem as áreas dos vasos ou do *background*. No terceiro e último estágio é executado um novo processo de filtragem para remoção de falsos positivos, executando um filtro baseado na circularidade de cada região e um filtro baseado na intensidade de pixels de cada região. O método alcançou uma sensibilidade de 78.5%, ao ser testado num conjunto de 75 imagens obtidas de hospitais. Das 75 imagens testadas, 25 eram de retinas normais e 50 eram imagens de retinas com lesões, delimitadas por oftalmologistas.

2.2 Conclusão

Este capítulo apresentou uma revisão de literatura sobre métodos de detecção de lesões vermelhas em imagens de fundo do olho. Pode-se constatar que operadores e transformadas de morfologia matemática foram amplamente empregados nos trabalhos supracitados, sendo que é possível encontrar algumas soluções essencialmente baseadas em morfologia matemática, como na obra de

Ravishankar et al. (2009), onde os operadores morfológicos são usados em todas as etapas.

Pode-se também identificar alguns problemas que são recorrentes nos trabalhos apresentados, como a dificuldade de distinção entre lesões vermelhas e vasos sanguíneos ou a distinção entre o disco óptico e os exsudatos (lesões brancas), uma vez que essas estruturas possuem uma intensidade de pixel muito parecida.

Na fase de pré-processamento, pode-se identificar alguns pontos em comum entre os diferentes métodos, como a extração do canal verde do esquema de cores RGB, devido ao seu melhor contraste comparando-o aos demais canais, além da correção de diferenças de iluminação utilizando filtro de medianas. Alguns exemplos são os trabalhos de Jaafar et al. (2011) e Ravishankar et al. (2009).

Um outro ponto constatado é a descrição superficial dos métodos na maioria dos artigos, dificultando sua implementação prática, a fim de testar a precisão do método. Observa-se também que vários trabalhos utilizam imagens não públicas, provenientes de hospitais locais ou de fonte não divulgada, como em Mariño et al. (2008) e Badea et al. (2008), o que inviabiliza a replicação dos experimentos apresentados nestes artigos.

Verificou-se que as imagens utilizadas são estritamente imagens de fundo do olho captadas de uma forma não-invasiva. Isso é praticamente uma constante nas publicações atuais da área, contrapondo várias publicações dos anos 80 e 90, onde alguns métodos utilizavam-se de técnicas invasivas para identificação das lesões, através de injeções intravenosas, a fim de realçar o contraste das lesões com o *background*.

Além disso, a maioria dos trabalhos foca na obtenção de altos índices de sensibilidade e não priorizando tanto a especificidade dos resultados. Isso torna o método sensível a diversas estruturas na imagem, com elevado número de falsos positivos. Pode-se destacar também que a maioria dos métodos concentra-se na detecção de lesões vermelhas não fazendo distinção entre hemorragias e microaneurismas, com exceção dos trabalhos de Shahin et al. (2012), que foca apenas na detecção de microaneurismas, e Hatanaka et al. (2008), que considera somente as hemorragias.

Também são poucos os trabalhos que propõe soluções híbridas, como em Niemeijer et al. (2005), onde combinam-se técnicas publicadas por diferentes autores na formulação de um novo método.

De certa forma a literatura já provê vários métodos recentes para detecção de lesões vermelhas em imagens de fundo do olho, o que denota a relevância do trabalho para o estado da arte. No entanto, considerando os trabalhos apresentados, o desafio atual está em obter altos índices tanto para sensibilidade quanto para especificidade, considerando a variabilidade de condições das lesões vermelhas, como a forma, tamanho, tonalidade e distribuição no *background*.

3 MORFOLOGIA MATEMÁTICA

Este capítulo apresenta conceitos básicos de morfologia matemática que foram empregados neste trabalho. Os operadores morfológicos são utilizados no processamento tanto de imagens binárias quanto de imagens em tons de cinza, sendo que será considerada neste capítulo apenas a definição dos operadores para imagens em tons de cinza. Será também demonstrada a aplicação desses operadores em imagens de fundo do olho.

Na seção 3.1 são apresentados alguns conceitos básicos de morfologia matemática, como o elemento estruturante; Na seção 3.2 são apresentados operadores e transformações fundamentais de morfologia matemática; Na seção 3.3, por fim, são apresentados operadores baseados em reconstrução morfológica.

3.1 Conceitos básicos


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). De acordo com Soille (2003), morfologia matemática pode ser definida como uma teoria para análise de estruturas espaciais, sendo chamada “morfologia” por ter como objetivo a análise das formas dos objetos, e “matemática”, pois é baseada em conceitos matemáticos como teoria dos conjuntos e geometria integral. Em Gonzales & Woods (2000) é destacado que a linguagem da morfologia matemática é a teoria dos conjuntos, sendo que estes conjuntos representam as formas dos objetos em uma imagem.

De fato, conforme observa Sonka et al. (2008), morfologia matemática é frequentemente utilizada em aplicações onde a forma dos objetos está em questão – por exemplo, análise de imagens microscópicas (em biologia, ciência dos materiais, geologia e criminologia), inspeção industrial, reconhecimento óptico de caracteres e análise de documentos. Segundo Wangenheim (2013), a base da morfologia matemática consiste em extrair as informações relativas à geometria e à topologia de uma imagem pela sua transformação através de um conjunto bem definido, denominado elemento estruturante.

De acordo com Ishikawa (2008), o elemento estruturante percorre uma imagem de entrada, pixel a pixel, realizando algumas transformações na vizinhança

do pixel que está sendo analisado e atribuindo o resultado ao pixel correspondente da nova imagem. Essa nova imagem, conforme observa Dougherty & Lotufo (2004), depende da escolha da forma e do tamanho do elemento estruturante. A Figura 3.1 apresenta formas comuns de elementos estruturantes, as quais estão presentes na biblioteca de morfologia matemática MMORPH (MMORPH, 2008).

Figura 3.1 – Elementos estruturantes típicos



O pixel central, destacado em cada forma da Figura 3.1, representa a origem do elemento estruturante, a qual será posicionada em cada pixel da imagem ao ser executada uma operação morfológica qualquer. Conforme observa Soille (2003), a forma e o tamanho do elemento estruturante devem ser adaptados de acordo com as propriedades geométricas dos objetos da imagem a ser processada, por exemplo, elementos estruturantes lineares são adequados para extração dos objetos lineares da imagem.

Portanto é fundamental a escolha correta da forma e do tamanho elemento estruturante, uma vez que a extração e/ou remoção de objetos da imagem está condicionada a esta decisão.

3.2 Operadores e transformações fundamentais de morfologia matemática em tons de cinza

Os operadores morfológicos básicos, conforme descreve Welfer (2011), são os operadores de dilatação, o qual é denotado por δ , e o operador de erosão, que é denotado por ε . O entendimento do funcionamento destes operadores é extremamente importante, uma vez que quaisquer outras operações morfológicas são derivadas dos operadores de dilatação ou erosão.

A dilatação 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 tende a ampliar as áreas de maior intensidade da imagem.

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

A erosão 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 tende a ampliar as áreas de menor intensidade da imagem.

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

Uma vez definidos os conceitos de dilatação e erosão, outros operadores podem ser derivados. Conforme observa Sonka et al. (2008), os contornos (ou bordas) da imagem podem ser obtidos subtraindo a imagem erodida da imagem dilatada. Este operador é conhecido como gradiente morfológico, o qual é denotado por ρB , conforme Equação 3.3 (SOILLE, 2003).

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

Podem-se definir também, a partir da utilização combinada dos operadores de dilatação e erosão, os operadores morfológicos de abertura e fechamento.

A operação de abertura 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, conforme Equação 3.4 (SOILLE, 2003). Conforme observa Serra (1982), a operação de abertura suaviza os contornos da imagem, corta istmos estreitos e remove pequenas ilhas.

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

A operação de fechamento de uma imagem f por um elemento estruturante B é denotada como $\phi^{(B)}f$ e é definida como a dilatação de f pelo elemento estruturante B , seguida pela erosão do resultado da dilatação pelo mesmo elemento estruturante, conforme Equação 3.5 (SOILLE, 2003). Conforme observa Zhao et al. (2006), a operação de fechamento une intervalos estreitos na imagem, elimina pequenos orifícios e preenche lacunas entre as bordas.

$$\phi^{(B)}f = \varepsilon^{(B)}(\delta^{(B)}(f)) \quad (3.5)$$

Podem-se definir, a partir da utilização combinada dos operadores de abertura e fechamento, filtros para remoção de ruídos na imagem, denominados Filtros Sequenciais Alternados (FSA). Estes filtros podem ser categorizados de duas formas, de acordo com a ordem de execução dos operadores: por abertura-fechamento e por fechamento-abertura.

No filtro sequencial alternado do tipo abertura-fechamento, denotado por $ASF_{co,B}^n(f)$, primeiramente executa-se a abertura morfológica $\gamma^{(B)}$ sobre a imagem f e após executa-se o fechamento morfológico $\phi^{(B)}$ sobre imagem resultante, utilizando o mesmo elemento estruturante B . Estas operações são repetidas n vezes conforme a Equação 3.6 (DOUGHERTY & LOTUFO, 2004), aumentando o tamanho do elemento estruturante a cada iteração. O filtro sequencial alternado do tipo fechamento-abertura, denotado por $ASF_{oc,B}^n(f)$, atua da mesma forma, mas executando primeiramente o fechamento morfológico $\phi^{(B)}$ e posteriormente a abertura morfológica $\gamma^{(B)}$, conforme Equação 3.7 (DOUGHERTY & LOTUFO, 2004).

$$ASF_{co,B}^n(f) = \phi^{(nB)}(\dots(\gamma^{2B}(\phi^{(B)}(\gamma^{(B)}(f)))) \dots) \quad (3.6)$$

$$ASF_{oc,B}^n(f) = \gamma^{(nB)}(\dots(\phi^{2B}(\gamma^{(B)}(\phi^{(B)}(f)))) \dots) \quad (3.7)$$

Baseando-se nos operadores de abertura e fechamento, pode-se definir também uma transformação morfológica denominada *top-hat*, a qual pode ser executada de duas formas: *top-hat* por abertura e *top-hat* por fechamento.

A transformação *top-hat* por abertura, conforme observa Dougherty & Lotufo (2004), tende a destacar os picos da imagem (áreas de maior intensidade). Esta transformação é denotada por γTH , e é obtida subtraindo a imagem que sofreu a abertura morfológica $\gamma^{(B)}f$ da imagem original f , utilizando um elemento estruturante

B. Esta transformação é mostrada na Equação 3.8 (JÄHNE; HAUßECKER; GEIßLER, 1999).

$$\gamma TH = f - \gamma^{(B)} f \quad (3.8)$$

A transformação *top-hat* por fechamento atua de modo oposto, destacando os vales da imagem (áreas de menor intensidade), conforme observa Dougherty & Lotufo (2004). Esta transformação é denota por $\emptyset TH$, e é obtida subtraindo a imagem original f da imagem que sofreu o fechamento morfológico $\emptyset^{(B)} f$, utilizando um elemento estruturante B . Esta transformação é mostrada na Equação 3.9 (JÄHNE; HAUßECKER; GEIßLER, 1999).

$$\emptyset TH = \emptyset^{(B)} f - f \quad (3.9)$$

Ao combinar-se a transformação *top-hat* por abertura com a transformação *top-hat* por fechamento, obtém-se uma imagem com um contraste melhorado (SOILLE, 2003). Esse realce de contraste é denotado por k^{TH} , e é obtido somando-se a imagem original f com a imagem que sofreu *top-hat* por abertura γTH , e posteriormente subtraindo deste resultado a imagem que sofreu *top-hat* por fechamento $\emptyset TH$, como pode ser visto na Equação 3.10 (SOILLE, 2003).

$$k^{TH} = f + \gamma TH - \emptyset TH \quad (3.10)$$


Uma vez definidos os operadores e transformações fundamentais de morfologia matemática, serão apresentados a seguir exemplos dessas operações aplicadas a uma imagem de fundo do olho.

A Figura 3.2 demonstra os operadores de dilatação e erosão aplicados a uma imagem de fundo do olho. Utilizou-se, em todas as operações, um elemento estruturante padrão, em formato de disco com um raio de cinco pixels de comprimento. Em (a) é mostrada a imagem original de fundo do olho, retirada do banco de imagens DIARETDB1 (KAUPPI et al., 2007); Em (b) é mostrada a mesma imagem de fundo de olho, a qual foi convertida em tons de cinza extraíndo-se o canal verde do espaço de cores RGB; Em (c) é mostrada a imagem (b) após a execução do operador de dilatação onde pode ser notado um aumento das áreas de maior intensidade, com o conseqüente afinamento dos vasos sanguíneos; Em (d) é mostrada a imagem (b) após a execução do operador de erosão, onde pode ser

notado um aumento das áreas de menor intensidade da imagem, com o conseqüente engrossamento dos vasos sanguíneos; Em (e), por fim, é mostrada a imagem (b) com as bordas realçadas, após a aplicação do gradiente morfológico.


A Figura 3.3 demonstra os operadores de abertura e fechamento aplicados a uma imagem de fundo do olho. Utilizou-se também, em todas as operações, um elemento estruturante padrão, em formato de disco com um raio de cinco pixels de comprimento. Em (a) é mostrada a imagem original em tons de cinza; Em (b) é mostrada a imagem (a) após sofrer abertura morfológica, onde foram removidas pequenas estruturas ao redor do disco óptico; Em (c) é mostrada a imagem (a) após sofrer fechamento morfológico, onde foram removidos os vasos sanguíneos mais finos devido à ação da dilatação; Em (d) é mostrada a imagem (a) após a aplicação da transformação morfológica *top-hat* por abertura, onde foram destacadas em branco as estruturas de cor mais clara da imagem, como pequenos exsudatos; Em (e) é mostrada a imagem (a) após a aplicação da transformação morfológica *top-hat* por fechamento, onde foram destacadas em branco as estruturas de cor mais escura da imagem, como os vasos sanguíneos; Em (f), por fim, é mostrada a imagem (a) após sofrer o realce de contraste proposto por Soille (2003).

Figura 3.2 – Dilatação e erosão de uma imagem de fundo do olho



(a) imagem original; (b) imagem em tons de cinza (canal verde); (c) imagem dilatada; (d) imagem erodida; (e) gradiente morfológico.

Figura 3.3 – Abertura e fechamento de uma imagem de fundo do olho



(a) imagem original em tons de cinza (canal verde); (b) imagem resultante do operador de abertura; (c) imagem resultante do operador de fechamento; (d) imagem com *top-hat* por abertura (imagem com o contraste melhorado para fins de visualização); (e) imagem com *top-hat* por fechamento (imagem com o contraste melhorado para fins de visualização); (f) imagem com o realce de contraste proposto por Soille (2003).

3.3 Reconstrução morfológica

De acordo com Dougherty & Lotufo (2004), uma das mais importantes operações do processamento morfológico de imagens é a reconstrução a partir de marcas. Até o momento foram apresentados operadores morfológicos que necessitam apenas de uma imagem de entrada. A reconstrução morfológica, no entanto, é obtida a partir dos chamados operadores geodésicos, os quais possuem duas imagens de entrada: um imagem marca, denotada por f ; e uma imagem máscara, denotada por g . Esses operadores geodésicos são o operador de dilatação geodésica e o operador de erosão geodésica.

A dilatação geodésica é denotada por $\delta_g^{(n)}(f)$, com $f \leq g$, e é mostrada na Equação 3.11 (JÄHNE; HAUBECKER; GEIBLER, 1999). O objetivo desse operador é dilatar a imagem f por n vezes, executando a operação de mínimo \wedge com a imagem g a cada dilatação. Assim, a ideia da dilatação geodésica é limitar a propagação da dilatação na imagem f (marca), uma vez que esta operação fica condicionada à imagem g (máscara).

$$\delta_g^{(n)}(f) = \delta_g^{(1)}\left(\delta_g^{(n-1)}(f)\right), \text{ com } \delta_g^{(1)} = \delta_g^{(1)} \wedge g \quad (3.11)$$

A erosão geodésica atua de forma semelhante à dilatação geodésica, e é denotada por $\varepsilon_g^{(n)}(f)$, com $f \geq g$, sendo mostrada na Equação 3.12 (JÄHNE; HAUBECKER; GEIBLER, 1999). O objetivo desse operador é erodir a imagem f por n vezes, executando a operação de máximo \vee com a imagem g a cada erosão. Assim, a ideia da erosão geodésica é limitar a propagação da erosão na imagem f (marca) uma vez que esta operação fica condicionada à imagem g (máscara).

$$\varepsilon_g^{(n)}(f) = \varepsilon_g^{(1)}\left(\varepsilon_g^{(n-1)}(f)\right), \text{ com } \varepsilon_g^{(1)} = \varepsilon_g^{(1)} \vee g \quad (3.12)$$

Conforme observa Bagesteiro (2013), 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. Essa estabilidade é alcançada quando a iteração corrente de uma operação geodésica sobre uma imagem f produz um resultado exatamente igual ao da iteração anterior, ou seja, a dilatação ou erosão ficou limitada à imagem g , definindo assim a reconstrução da imagem. A reconstrução por dilatação é denotada por $R_g(f)$, e é

mostrada na Equação 3.13; A reconstrução por erosão é denotada por $R_g^*(f)$, sendo mostrada na Equação 3.14 (JÄHNE; HAUßECKER; GEIßLER, 1999) .

$$R_g(f) = \delta_g^{(i)}(f), \text{ onde } i \text{ é tal que } \delta_g^{(i)}(f) = \delta_g^{(i+1)}(f) \quad (3.13)$$

$$R_g^*(f) = \varepsilon_g^{(i)}(f), \text{ onde } i \text{ é tal que } \varepsilon_g^{(i)}(f) = \varepsilon_g^{(i+1)}(f) \quad (3.14)$$

De acordo com Welfer (2011), a partir da ideia de reconstrução por dilatação e reconstrução por erosão, é possível definir o operador de máximos regionais, $RMAX$, e o operador de mínimos regionais, $RMIN$.

O operador de máximos regionais é baseado em reconstrução por dilatação e segundo Dougherty & Lotufo (2004) destaca áreas na imagem que não estão cercadas por áreas de maior intensidade. Esse operador recebe uma imagem em tons de cinza e retorna uma imagem binária. Conforme observa Welfer (2011), se uma região na imagem possuir um valor de intensidade maior que seus pixels vizinhos, então o valor lógico “1” é atribuído para todos os pixels deste conjunto, caso contrário “0” é atribuído para todos os pixels do conjunto. O operador de máximos regionais $RMAX$ aplicado a uma imagem f é definido na Equação 3.15 (JÄHNE; HAUßECKER; GEIßLER, 1999).

$$RMAX(f) = f + 1 - R_{f+1}(f) \quad (3.15)$$

O operador de mínimos regionais é baseado em reconstrução por erosão e atua de forma semelhante ao operador de máximos regionais, diferenciando-se por destacar áreas na imagem que não estão cercadas por áreas de menor intensidade. O operador de mínimos regionais $RMIN$ aplicado a uma imagem f é definido na Equação 3.16 (JÄHNE; HAUßECKER; GEIßLER, 1999).

$$RMIN(f) = R_f^*(f + 1) - f \quad (3.16)$$

É possível, ainda, a partir da ideia de reconstrução por dilatação definir a transformada H -máxima, e a partir da reconstrução por erosão definir a transformada H -mínima. As transformadas H -máxima e H -mínima permitem filtrar os extremos da imagem utilizando um critério de contraste (BAGESTEIRO, 2013).

A transformada H -máxima remove os picos conectados (regiões de alto contraste) de uma imagem f , os quais possuem um contraste menor que um limite h ,

e é definida pela Equação 3.17. A transformada *H-mínima*, por sua vez, remove os vales conectados (regiões de baixo contraste) de uma imagem f , os quais possuem um contraste menor que um limite h , e é definida pela Equação 3.18 (SOILLE, 2003).

$$Hmax_h(f) = R_f(f - h) \quad (3.17)$$


$$Hmin_h(f) = R_f^*(f + h) \quad (3.18)$$

Um operador para preenchimento de buracos na imagem, denominado *FILL*, pode ser derivado a partir de uma reconstrução por dilatação. Soille (2003) define tais buracos como o conjunto dos mínimos regionais que não estão conectados a borda da imagem. O operador *FILL* é apresentado na Equação 3.19 (DOUGHERTY & LOTUFO, 2004), utilizando o complemento da imagem de entrada, f^c , como máscara, e uma “imagem quadro” ∂f como marca para a reconstrução. Uma imagem quadro ∂f tem o mesmo tamanho da imagem de entrada f , possuindo a cor branca nos pixels da borda e a cor preta nos demais pixels.

$$FILL(f) = (R_{f^c}(\partial f))^c \quad (3.19)$$

Uma vez apresentados os principais operadores e transformadas baseados em reconstrução morfológica, serão mostrados agora exemplos dessas operações aplicadas a uma imagem de fundo do olho, conforme Figura 3.4. Utilizou-se em todas as operações, um elemento estruturante padrão, em formato de disco com um raio de cinco pixels de comprimento. Em (a) é mostrada a imagem original em tons de cinza; Em (b) é criada uma imagem marca f a partir da operação de *top-hat* por fechamento sobre a imagem (a), destacando apenas as áreas de baixa intensidade da imagem original; Em (c) é mostrada a imagem de (b) reconstruída por dilatação, utilizando (b) como a imagem marca f , e (a) como a imagem máscara g ; Em (d) é mostrada a execução da transformada *H-mínima* sobre a imagem (a), utilizando um limite de contraste h de 120; pode-se notar que as áreas conectadas de baixa intensidade foram removidas, preservando-se as áreas mais claras, como a área do disco óptico não que não estava sobreposta pelos vasos e também a maioria dos exsudatos; E em (e), por fim, a imagem (d) é binarizada a partir da execução do operador de mínimos regionais, atribuindo o valor lógico “1” para as áreas de baixa intensidade e o valor lógico “0” para as áreas de alta intensidade.


Figura 3.4 – Operadores baseados em reconstrução morfológica




(a) imagem original em tons de cinza (canal verde); (b) imagem de (a) após sofrer *top-hat* por fechamento (imagem com o contraste melhorado para fins de visualização); (c) imagem de (b) reconstruída por dilatação; (d) imagem de (b) após a execução da transformada *H-mínima*; (e) imagem de (d) após a execução do operador de mínimos regionais.

Na Figura 3.5 é mostrado um exemplo do operador morfológico *FILL*. Em (a) é mostrada a imagem de entrada f onde foi utilizado o complemento da Figura 3.4 (e), destacando um buraco a ser preenchido pelo operador. E em (b), é mostrada a imagem resultante do *FILL*, com a área destacada preenchida.

Figura 3.5 – Operador *FILL*



(a)



(b)

(a) imagem de entrada para o *FILL*, com área a ser preenchida em destaque; (b) imagem resultante do operador *FILL*.

4 MATERIAIS E MÉTODOS

Neste capítulo são apresentados os materiais utilizados para a execução desta pesquisa, os quais são descritos na seção 4.1, como também o método de detecção de lesões vermelhas proposto por este trabalho, o qual é descrito na seção 4.2. A seção 4.3, por fim, realiza o fechamento do capítulo.


4.1 Materiais para detecção de microaneurismas e hemorragias

Ao longo desta pesquisa, utilizou-se o banco de dados público de imagens de fundo de olho DIARETDB1 (KAUPPI et al., 2007) . Esta base de dados possui uma grande variabilidade de lesões que caracterizam a RD, além de ser uma das mais utilizadas nas publicações atuais da área.

O DIARETDB1 foi organizado por um grupo de pesquisadores finlandeses, motivados pelo fato de não existir uma base de dados comum nas publicações de métodos de detecção de RD, o que impossibilitava provar a confiabilidade e precisão de cada algoritmo proposto.


O DIARETDB1 possui um total de 89 imagens de fundo de olho (RGB), de tamanho 1500 x 1152 pixels. Deste total, 84 imagens possuem sinais característicos de RD, tais como microaneurismas, hemorragias e exsudatos, e 5 imagens são de retinas normais.

Na concepção do DIARETDB1, em cada imagem de fundo do olho, as regiões com manifestação de lesões foram destacadas manualmente por quatro especialistas em oftalmologia, os quais fizeram essa análise individualmente. Ao fim, ocorreram disparidades no resultado de cada uma das quatro análises - nem todas as áreas lesionadas foram de decisão unânime, por exemplo. Assim, tomou-se a união das quatro análises, formando o *ground-truth* de cada imagem, o qual também é disponibilizado pelo DIARETDB1. A Figura 4.1 mostra um exemplo de uma imagem de fundo do olho com seu respectivo *ground-truth*, ou seja, as regiões com incidência de lesões vermelhas (hemorragias e microaneurismas), delimitadas manualmente por especialistas.

Figura 4.1 – *Ground-truth* do DIARETDB1

(a) imagem de fundo do olho com lesões; (b) *ground-truth* das hemorragias; (c) *ground-truth* dos microaneurismas.

No entanto, um problema apresentado neste *ground-truth* é a falta de precisão na marcação das lesões, uma vez que os oftalmologistas delimitaram áreas com um conjunto de lesões e não cada lesão em si. Assim, optou-se por utilizar neste trabalho o *ground-truth* do DIARETDB1 aprimorado por Bagesteiro (2013), o qual identifica cada lesão individualmente, mescla na mesma imagem microaneurismas e hemorragias, e desconsidera lesões de pouco consenso entre os oftalmologistas (destacadas por apenas um ou dois especialistas). Neste novo *ground-truth*, dentre as 89 imagens, 53 foram definidas como imagens com lesões, e 36 como imagens sem lesões. A Figura 4.2 compara o *ground-truth* original do DIARETDB1, referente a uma imagem com lesões, com o *ground-truth* modificado por Bagesteiro (2013), referente a essa mesma imagem da retina.

Figura 4.2 – *Ground-truth* modificado

(a) *ground-truth* original das hemorragias (DIARETDB1); (b) *ground-truth* original dos microaneurismas (DIARETDB1); (c) *ground-truth* modificado por Bagesteiro (2013), mesclando hemorragias e microaneurismas e desconsiderando regiões de pouco consenso entre os oftalmologistas.

A implementação do método proposto neste trabalho foi realizada utilizando o software MATLAB (MathWorks, 1994), através da biblioteca de morfologia matemática MMORPH (2008) (DOUGHERTY; LOTUFO, 2003), uma vez que o método é fundamentalmente baseado em operadores morfológicos, conforme será descrito na seção a seguir.

4.2 Método para detecção de microaneurismas e hemorragias


O método para detecção de lesões vermelhas proposto neste trabalho é baseado num algoritmo de cinco etapas, a saber: 1) pré-processamento da imagem; 2) destaque das estruturas escuras da imagem; 3) detecção dos vasos sanguíneos; 4) eliminação dos vasos sanguíneos; e 5) eliminação da fóvea. Conforme será visto nas seções a seguir, cada etapa possui um conjunto de passos. Para um melhor

entendimento do algoritmo, as imagens resultantes de cada passo serão representadas pela variável f_i , onde i identifica o passo.

4.2.1 Pré-processamento da imagem

Esta etapa consiste basicamente na aplicação de um melhoramento de contraste nas imagens de fundo do olho. Primeiramente realizou-se um redimensionamento das imagens do DIARETDB1 para o tamanho 640 x 480 pixels. Este mapeamento para um tamanho menor é importante, pois tem como objetivo reduzir o tempo de processamento do método. Logo após, a partir da imagem de entrada, extraiu-se o canal verde do esquema RGB, o qual possui um melhor contraste ao ser comparado aos demais canais (JAAFAR et al., 2011). A Figura 4.3 mostra uma imagem de fundo do olho, comparando os três canais do esquema RGB.

Figura 4.3 – Comparação dos três canais RGB



(a) imagem original de fundo do olho; (b) canal vermelho; (c) canal verde; (d) canal azul. Cada canal teve seu contraste melhorado para fins de visualização.

A extração do canal verde da imagem de entrada f é indicada pela variável f_1 e é definida na Equação 4.1.


$$f1 = \text{GreenChannel}(f) \quad (4.1)$$

Após esta operação, aplicou-se uma técnica de realce de contraste denominada filtro CLAHE (*Contrast Limited Adaptive Histogram Equalization*). Esta técnica consiste em dividir a imagem em blocos de tamanhos iguais, e aplicar uma equalização de histograma em cada bloco. Após, define-se um limite de corte para o contraste, sendo que os histogramas de cada bloco são recalculados de forma não ultrapassar este limite.

Assim, obtém-se a imagem $f2$, utilizando blocos de tamanho 10×10 e um limite de contraste de 0.8.

$$f2 = \text{CLAHE}(f1) \quad (4.2)$$

Figura 4.4 – Pré-processamento da imagem



(a) imagem $f1$: canal verde do esquema RGB; (b) imagem $f2$: filtro CLAHE.

4.2.2 Destaque das estruturas escuras da imagem

O objetivo desta etapa se resume em destacar todas as estruturas escuras da imagem, ou seja, os vasos sanguíneos, a fóvea e as lesões vermelhas.

Primeiramente, aplicou-se um Filtro Sequencial Alternado (FSA) do tipo abertura-fechamento, a fim de estimar o *background* $f3$ da imagem $f2$. O filtro é demonstrado na Equação 4.3, onde n é o número de iterações (utilizou-se 3), e B é um elemento estruturante em forma de disco com um raio de 5 pixels de comprimento. A imagem resultante desta operação é mostrada na Figura 4.5 (a).

$$f3 = \phi^{(nB)}(\dots(\gamma^{2B}(\phi^{(B)}(\gamma^{(B)}(f2)))) \dots) \quad (4.3)$$

Logo após, uma nova imagem $f4$, com redução de ruídos no *background* é obtida, conforme a Equação 4.4. A imagem resultante desta operação é mostrada na Figura 4.5 (b), onde já pode ser notada uma inversão de intensidade entre os pixels do *foreground* e do *background*, ao comparar-se com a imagem $f1$.

$$f4 = f3 - f2 \quad (4.4)$$


No passo seguinte aplicou-se um filtro de contraste através da transformada *H-mínima*. Este filtro remove vales conectados na imagem (áreas de baixa intensidade) que possuem um contraste menor que um limite h . Como na imagem $f4$ as intensidades de cor foram invertidas, esta operação tende a remover resquícios de lesões brancas (exsudatos, presentes em algumas imagens de fundo do olho). Assim, obtém-se a imagem $f5$, de acordo com a Equação 4.5. Utilizou-se o valor 1 para o limite de contraste h . A imagem resultante desta operação é mostrada na Figura 4.5 (c).

$$f5 = Hmin_h(f4) \quad (4.5)$$

Logo após, aplicou-se o operador de mínimos regionais a fim de binarizar a imagem $f5$, conforme a Equação 4.6, onde c representa o complemento da imagem. Assim, obtém-se a imagem $f6$, com as estruturas de cor mais escura destacadas em branco. O resultado desta operação pode ser visto na Figura 4.5 (d).

$$f6 = RMIN(f5)^c \quad (4.6)$$

Figura 4.5 – Destaque das estruturas escuras da imagem



(a) imagem f_3 : Filtro Sequencial Alternado (FSA); (b) imagem f_4 : menos ruído no *background*; (c) imagem f_5 : transformada *H-mínima*; (d) imagem f_6 : complemento dos mínimos regionais.

4.2.3 Detecção dos vasos sanguíneos

Nesta etapa os vasos sanguíneos foram detectados utilizando operadores baseados em reconstrução morfológica.

O *background* da imagem f_2 foi novamente estimado através de um Filtro Sequencial Alternado (FSA) do tipo abertura-fechamento, de acordo com a Equação 4.7. Aqui, no entanto, o elemento estruturante B é um disco com um raio de 3 pixels de comprimento e o total de iterações n foi definido com o valor 1. O resultado desta operação pode ser visto na imagem 4.6 (a).

$$f_7 = \emptyset^{(nB)}(\dots(\gamma^{2B}(\emptyset^{(B)}(\gamma^{(B)}(f_2))))\dots) \quad (4.7)$$

Logo após, uma nova imagem f_8 , sem variações no *background* é obtida, conforme a Equação 4.8. A imagem resultante desta operação é mostrada na Figura 4.6 (b).

$$f_8 = f_7 - f_2 \quad (4.8)$$

No passo seguinte, a detecção dos vasos sanguíneos foi implementada utilizando a abertura morfológica γ de f_8 com elementos estruturantes multi-escalares, em um processo semelhante ao proposto por Neimeijer et al. (2005). A abertura morfológica γ foi executada 12 vezes sobre a imagem f_8 , utilizando 12 elementos estruturantes lineares com diferentes ângulos de inclinação, variando 15 graus a cada elemento estruturante (ou seja, 0°, 15°, 30°, e assim por diante, até 165°). Este intervalo de graus foi escolhido de forma que as diferentes linhas que formam a cadeia de vasos fossem contempladas. Como os vasos sanguíneos possuem uma característica geométrica linear e alongada, o comprimento do elemento estruturante foi definido em 40 pixels, de forma que as aberturas morfológicas não extraíssem estruturas arredondadas, que poderiam estar associadas às lesões vermelhas ou a fóvea. Ao final, somaram-se as 12 imagens que sofreram a abertura morfológica, obtendo-se a imagem f_9 , com um esboço da cadeia de vasos. Esta soma é apresentada na Equação (4.9), onde i identifica cada uma das aberturas e n é definido com o valor 12. A imagem resultante desta soma pode ser verificada na Figura 4.6 (c).

$$f_9 = \sum_{i=1}^{i=n} \gamma^{(Bi)} f_8 + \gamma^{(Bi+1)} f_8 + \dots + \gamma^{(Bn)} f_8 \quad (4.9)$$


No passo seguinte, os vasos sanguíneos foram reconstruídos, aplicando-se uma reconstrução por dilatação da imagem “marca” f_9 sobre a imagem “máscara” f_8 , conforme a Equação 4.10. Esta operação reconstrói os componentes conectados da imagem f_8 que também existem na imagem f_9 , que contém o esboço dos vasos. Nesta operação, utilizou-se um elemento estruturante em forma de diamante, com raio de 1 pixel. A imagem resultante desta operação é mostrada na Figura 4.6 (d).

$$f_{10} = R_{f_8}(f_9) \quad (4.10)$$

Logo após, a imagem f_{10} foi binarizada aplicando-se o operador de mínimos regionais, conforme a Equação 4.11, onde c é o complemento da imagem. A imagem resultante f_{11} contém os vasos sanguíneos detectados e é mostrada na Figura 4.6 (e).

$$f_{11} = RMIN(f_{10})^c \quad (4.11)$$

Figura 4.6 – Detecção dos vasos sanguíneos




(a) imagem f_7 : Filtro Sequencial Alternado (FSA); (b) imagem f_8 : menos ruído no *background*; (c) imagem f_9 : soma de aberturas morfológicas; (d) imagem f_{10} : vasos reconstruídos; (e) imagem f_{11} : complemento dos mínimos regionais dos vasos.

4.2.4 Eliminação dos vasos sanguíneos

Esta etapa consiste em subtrair os vasos sanguíneos (f_{11}), obtidos na etapa anterior, da imagem f_6 , que contém as estruturas escuras. Esta operação é definida pela Equação 4.12 e a imagem resultante é mostrada na Figura 4.7.

$$f_{12} = f_6 - f_{11} \quad (4.12)$$

Figura 4.7 – Eliminação dos vasos sanguíneos



4.2.5 Eliminação da fóvea

Na quinta e última etapa do método, o objetivo é a eliminação da região da fóvea da imagem f_{12} , de forma que nessa imagem permaneçam apenas as regiões candidatas a lesões vermelhas.

Primeiramente aplicou-se um algoritmo que identifica o centro da fóvea, baseado em características da anatomia da retina, o qual considera a relação espacial entre o diâmetro do disco óptico e a região da fóvea (WELFER, SCHARCANSKI, MARINHO, 2010). Obteve-se aqui uma imagem binária denominada *FoveaCentro*, que possui apenas um pixel de valor 1, o qual identifica o centro da fóvea.

Logo após, o centro da fóvea foi dilatado com um elemento estruturante em forma de disco com raio de 25 pixels de comprimento, uma vez que a fóvea possui características geométricas circulares e possui tamanho similar a este definido. Esta operação é definida na Equação 4.13 e a imagem resultante é mostrada na Figura 4.8 (a).

$$f13 = \delta^{(B)}(FoveaCentro) \quad (4.13)$$

Logo após, a fóvea foi removida subtraindo a imagem $f13$ (que possui a região estimada da fóvea) da imagem $f12$ (que possui os candidatos a lesões vermelhas). Esta operação é definida na Equação 4.14 e a imagem resultante é mostrada na Figura 4.8 (b).

$$f14 = f12 - f13 \quad (4.14)$$


No passo seguinte, utilizou-se o mesmo procedimento adotado por Bagesteiro (2013) para eliminação dos ruídos ainda presentes na imagem. Após a remoção da fóvea, aplicou-se uma operação morfológica de fechamento de buracos denotada por *FILL*; Logo após, aplicou-se uma abertura morfológica com um elemento estruturante B em forma de diamante com raio de 1 pixel; Por fim, a imagem foi dilatada com este mesmo elemento estruturante. Estas operações são definidas pela Equação 4.15 e a imagem resultante é mostrada na Figura 4.8 (c).

$$f15 = \delta^{(B)}(\gamma^{(B)}(FILL(f14))) \quad (4.15)$$

O próximo passo é o procedimento final do método, o qual consiste em aplicar uma máscara disponibilizada pelo DIARETDB1, a qual exclui os pixels do contorno da imagem. A máscara é definida pela Equação 4.16 e a imagem resultante é mostrada na Figura 4.8 (d).

$$f16_{(x,y)} = \begin{cases} 0, & \text{se } mask_{(x,y)} = 0 \\ f15_{(x,y)}, & \text{caso contrário} \end{cases} \quad (4.16)$$

Figura 4.8 – Eliminação da fóvea

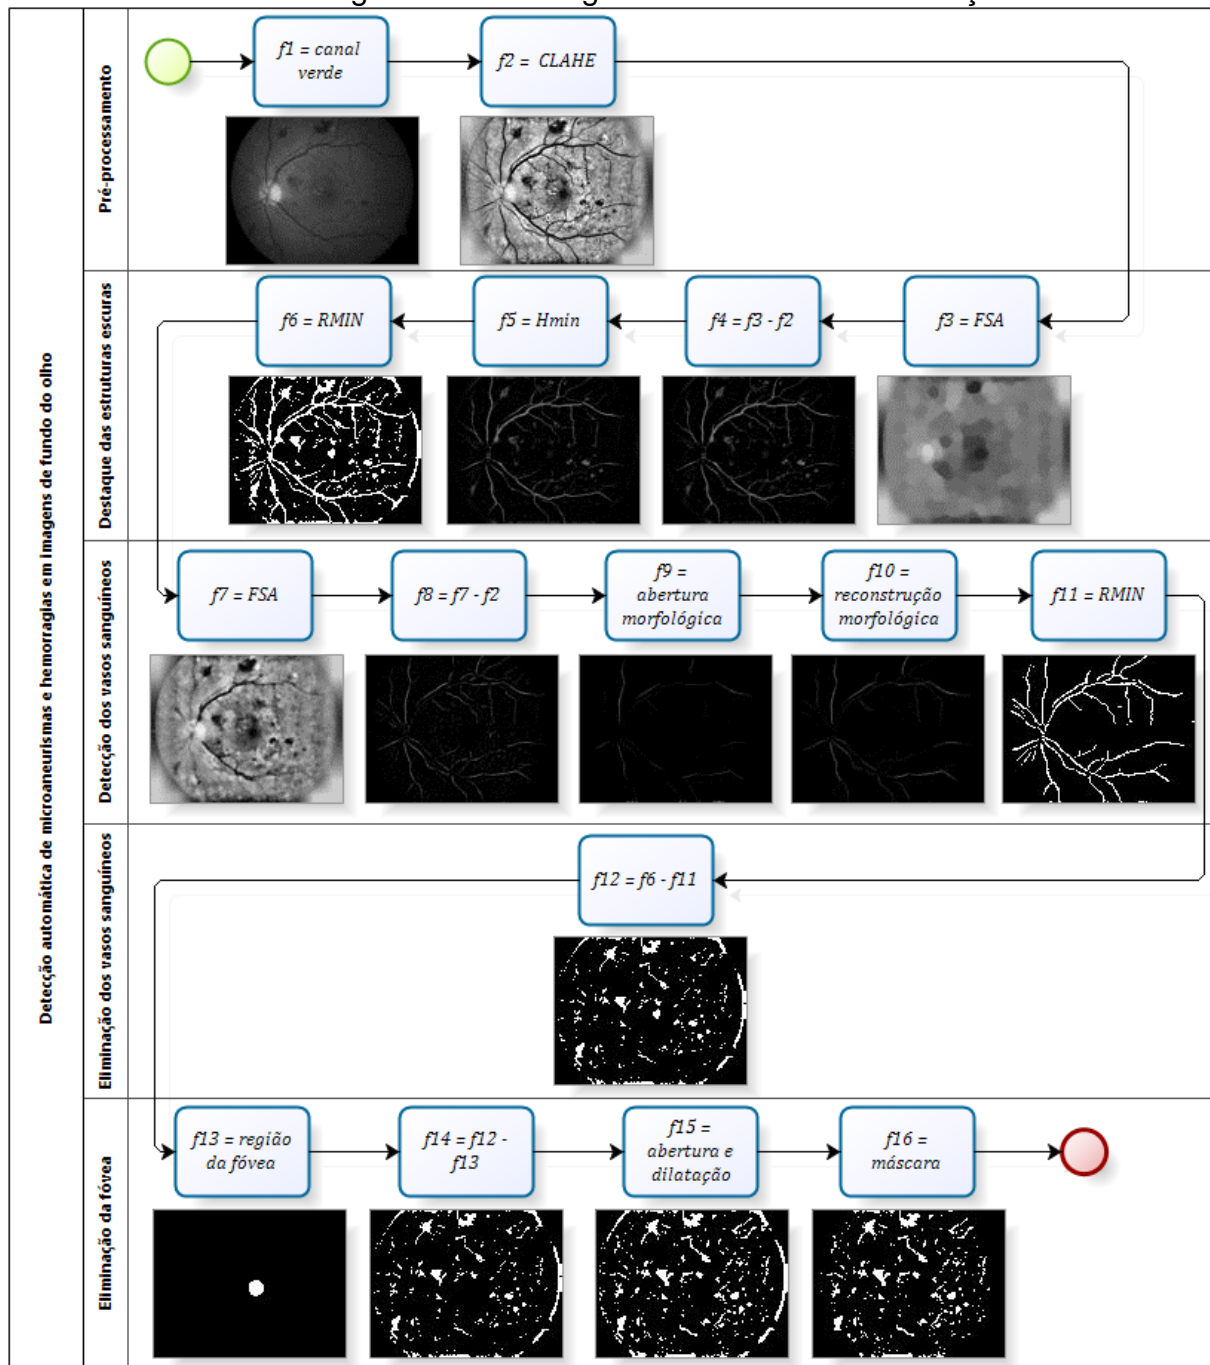


(a) imagem f_{13} : centro da fóvea dilatado; (b) imagem f_{14} : região da fóvea eliminada; (c) imagem f_{15} : remoção de ruídos; (d) imagem f_{16} : aplicação da máscara.

4.2.6 Fluxograma do método

Nesta seção o método de detecção de lesões vermelhas proposto por este trabalho é apresentado resumidamente em forma de fluxograma, tendo em vista facilitar o entendimento do mesmo. O fluxograma do método é apresentado na Figura 4.9.

Figura 4.9 – Fluxograma do método de detecção



4.3 Conclusão

Neste capítulo foram apresentados os materiais utilizados para a execução desta pesquisa, onde foi destacada a utilização da base de dados pública de imagens de fundo do olho DIARETDB1. A utilização de um banco de dados público é importante visando à possibilidade de outros autores reproduzirem os experimentos propostos, onde pode ser testada a confiabilidade e precisão do método. Foi também apresentado o conceito de *ground-truth*, onde neste trabalho

optou-se por utilizar um *ground-truth* aprimorado do DIARETDB1, o qual delimita as regiões lesionadas com maior precisão e descarta áreas de pouco consenso entre os oftalmologistas.

O capítulo também apresentou o método de detecção de lesões vermelhas proposto por este trabalho. O método é baseado num algoritmo de cinco etapas, as quais possuem uma sequência distinta de passos. A solução apresentada é essencialmente baseada em operadores e transformações de morfologia matemática, uma vez que esses conceitos são utilizados em praticamente todos os passos do método.

Na primeira etapa do método, o pré-processamento, aplicou-se uma equalização de histograma por regiões (filtro CLAHE) para melhoramento de contraste, abordagem que também foi utilizada por alguns dos trabalhos estudados, como Shahin et al. (2012) e Bagesteiro (2013). Na segunda etapa, optou-se pelo destaque de todas as estruturas escuras da imagem, ou seja, os vasos sanguíneos, a fóvea e as lesões vermelhas; Na terceira etapa, foi definido um método de detecção de vasos sanguíneos baseado em reconstrução morfológica. Para a criação da imagem “marca”, utilizou-se a operação de abertura morfológica da imagem com elementos estruturantes lineares de diferentes ângulos; uma abordagem semelhante a esta pode ser encontrada no trabalho de Neimeijer (2005), sem utilizar, no entanto, conceitos de reconstrução morfológica; Na quarta etapa foi realizada a subtração dos vasos sanguíneos da imagem com as estruturas escuras, tentando eliminar o mínimo possível de lesões vermelhas sobrepostas aos vasos; Na quinta e última etapa utilizou-se o método proposto por Welfer, Scharcanski & Marinho (2010) para a identificação do centro da fóvea e, logo após, foram utilizadas operações morfológicas para a remoção da região da fóvea.

5 DISCUSSÃO E RESULTADOS EXPERIMENTAIS

Neste capítulo são apresentados os resultados alcançados pelo método de detecção de lesões vermelhas proposto por este trabalho.

A seção 5.1 apresenta as medidas utilizadas para quantificar os resultados; e a seção 5.2 apresenta e discute os resultados alcançados pelo método de detecção.

5.1 Medidas utilizadas para quantificação dos resultados

Para quantificar os resultados alcançados pelo método de detecção foram utilizadas as medidas de sensibilidade e especificidade. Essas medidas foram escolhidas baseando-se nos trabalhos relacionados estudados, onde a maioria das publicações utiliza essas medidas.

Para um entendimento claro dessas medidas é necessário conceituar algumas classificações utilizadas em testes de laboratório para detecção de doenças. Quando o resultado de um teste for positivo, o indivíduo pode manifestar a doença, o que caracteriza um “Verdadeiro Positivo” (VP) ou pode não manifestá-la, o que é denominado de “Falso Positivo” (FP). Por outro lado, quando o resultado de um teste for negativo, o indivíduo pode não ter a doença, o que é denominado de “Verdadeiro Negativo” (VN), como pode manifestá-la, o que é denominado de “Falso Negativo” (FN) (OBID, 2013).

Conforme observado em OBID (2013), a sensibilidade é a fração dos que obtiveram resposta positiva no teste entre aqueles que possuem a doença, e é indicada na Equação 5.1. Em PTB (2013) a sensibilidade é conceituada como “a capacidade de um teste detectar corretamente as pessoas com a doença/condição”.

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

A especificidade, por sua vez, é definida em OBID (2013) como a fração dos que obtiveram resposta negativa no teste entre aqueles que não possuem a doença, e é indicada na Equação 5.2. Em PTB (2013), a especificidade é definida como “a capacidade de um teste excluir corretamente as pessoas sem a doença/condição”.

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

É importante que exista certo equilíbrio entre os valores de sensibilidade e especificidade. Obter valores altos para sensibilidade e baixos para especificidade significa que o método detectou a maioria das lesões (verdadeiros positivos), mas classificou erroneamente outras estruturas como sendo lesões (falsos positivos). Por outro lado, obter valores altos para especificidade e baixos para sensibilidade, significa que o método excluiu corretamente as regiões não lesionadas (verdadeiros negativos), mas não foi capaz de identificar todas as lesões (verdadeiros positivos).

5.2 Resultados alcançados pelo método de detecção

O método de detecção foi testado nas 89 imagens do banco DIARETDB1, separando os resultados das imagens com lesões dos resultados das imagens sem lesões.


Para realizar a contabilização dos pixels de VP, FN, FP e VN cada imagem resultante do método foi comparada com o seu *ground-truth*, onde foi feita uma análise baseada na área de cada região da imagem. Na Tabela 5.1 são demonstradas as médias dos valores de VP, FN, FP e VN.

Tabela 5.1 – Média dos valores de VP, FN, FP e VN

Análise	Verdadeiro Positivo	Falso Negativo	Falso Positivo	Verdadeiro Negativo
Imagens com lesões	1809.62	329.73	23012.45	282048.18
Imagens sem lesões	0	0	17054.50	290145.50

A Figura 5.1 (a) mostra o canal verde de uma imagem de fundo do olho contendo microaneurismas e hemorragias. A Figura 5.1 (b) mostra o *ground-truth* da imagem. A Figura 5.1 (c) mostra os microaneurismas e hemorragias detectados. As Figuras 5.1 (d)-(g) mostram os pixels de verdadeiros positivos, falsos negativos, falsos positivos e verdadeiros negativos, respectivamente.

Figura 5.1 – Ilustração dos falsos positivos/negativos e dos verdadeiros positivos/negativos



(a) Canal verde da imagem original. (b) *Ground-truth* da imagem. (c) Hemorragias e microaneurismas detectados. (d) Pixels de verdadeiros positivos. (e) Pixels de falsos negativos. (f) Pixels de falsos positivos. (g) Pixels de verdadeiros negativos.

As medidas de sensibilidade e especificidade foram calculadas por imagem, e ao fim realizou-se a média geral dos valores obtidos em cada imagem, onde o método obteve 87.69% de sensibilidade e 92.44% de especificidade na análise das imagens com lesões, conforme a Tabela 5.2.

Tabela 5.2 – Resultados do método de detecção proposto

Análise	Sensibilidade	Especificidade
Imagens com lesões	87.69%	92.44%
Imagens sem lesões	-	94.44%

Na análise de imagens sem lesões não são gerados os resultados de sensibilidade, pois as medidas de VP e FN nesse caso são iguais à zero.

Os resultados individuais de sensibilidade e especificidade obtidos em cada imagem com lesão podem ser visualizados no Apêndice A; e no Apêndice B é mostrada a especificidade em cada imagem sem incidência de lesões. Um comparativo com os demais trabalhos da literatura, quanto às medidas de sensibilidade e especificidade, pode ser visualizado na Tabela 5.3.

Tabela 5.3 – Comparativo entre os trabalhos relacionados


Autor(es)	Imagens públicas?	Sensibilidade	Especificidade
Jaafar et al. (2011)	Sim: DIARETDB0 e DIARETDB1	98.8%	86.2%
Niemeijer et al. (2005)	Não	100%	87%
Ravishankar et al. (2009)	Algumas: DIARETDB0, DRIVE e STARE	95.1%	90.5%
Balasubramanian et al. (2008)	Não especificado	87%	95.53%
Badea et al. (2008)	Não especificado	Não especificado	Não especificado
Kande et al. (2010)	Algumas: STARE, DIARETDB0 e DIARETDB1	100%	91%
Shahin et al. (2012)	Sim: STARE, DRIVE, DIARETDB0 e DIARETDB1	88%	100%
Roychowdhury et al. (2012)	Sim: DIARETDB1	75.5%	93.73%
Garcia et al. (2008)	Não	100%	60%
Hatanaka et al. (2008)	Não	80%	80%
Esmaeili et al. (2010)	Sim: DIARETDB1	94%	87%
Mariño et al. (2008)	Não	78.5%	Não especificado
Este Trabalho	Sim: DIARETDB1	87.69%	92.44%

Analisando os trabalhos apresentados na Tabela 5.3, pode-se constatar que a maioria das publicações que utilizam imagens públicas, tiveram seus métodos testados nas imagens providas pelo banco de dados de imagens de fundo de olho DIARETDB1 (KAUPPI et al., 2007). Este foi um fator determinante para a escolha desta base de dados para este trabalho, uma vez que a mesma é utilizada na maioria das publicações atuais da área, além do fato deste banco de dados possuir uma grande variabilidade de lesões que caracterizam a retinopatia diabética.

Na Figura 5.2 é possível visualizar uma imagem de saída do método de detecção com seu respectivo *ground-truth*. A imagem analisada obteve uma medida de sensibilidade de 86% e uma especificidade de 91%, sendo possível constatar que o método conseguiu identificar a maioria das lesões apesar dos falsos positivos ainda presentes na imagem.


Estes falsos positivos são ocasionados, dentre outros motivos, por resquícios de vasos sanguíneos, onde houve certa ineficiência do método em eliminar os vasos sem remover as lesões sobrepostas aos mesmos. A Figura 5.3 ilustra essa deficiência do método analisando a mesma imagem de fundo do olho utilizada na Figura 5.2. As áreas de vasos sanguíneos indevidamente mantidas estão destacadas em com uma seta vermelha.

Figura 5.2 – Exemplo de uma imagem de saída do método de detecção




(a) Imagem original tons de cinza número 22; (b) *ground-truth* dos microaneurismas e hemorragias; (c) imagem de saída do método; (d) *ground-truth* sobreposto à imagem de saída.

Figura 5.3 – Problemas na eliminação dos vasos sanguíneos




Um outro problema constatado, o qual afetou a sensibilidade, ocorreu na quinta etapa do método, onde a eliminação da região da fóvea acabou removendo algumas sobrepostas a essa região. Na Figura 5.4 pode ser visualizada essa falha, utilizando a mesma retina da Figura 5.2. As lesões vermelhas sobrepostas à circunferência referente à região da fóvea foram indevidamente removidas pelo método.

Figura 5.4 – Problemas na eliminação da região da fóvea




Um outro fator, que acabou afetando a sensibilidade, foi a não detecção de lesões muito pequenas, pois o método acabou não identificando alguns microaneurismas que ocupavam uma área de pixel reduzida, conforme mostrado no *ground-truth* da Figura 5.5. Devido ao seu tamanho muito pequeno, algumas poucas lesões foram confundidas com ruído e acabaram sendo removidas indevidamente.

Figura 5.5 – Problemas na identificação de lesões pequenas



Uma dificuldade enfrentada, que é recorrente nas publicações da área, são as diferenças de iluminação presentes em algumas imagens, conforme pode ser visto na Figura 5.6. Pode-se perceber que a parte inferior da imagem sofre deste problema de iluminação (a), onde o realce de contraste (filtro CLAHE) acabou aumentando a disparidade de intensidade entre as áreas claras e escuras (b), acarretando que algumas regiões fossem incorretamente classificadas como áreas escuras na segunda etapa do método (c). Dessa forma, essas regiões persistiram até o último passo do método (d).

Figura 5.6 – Problemas com diferenças de iluminação




(a) Imagem original tons de cinza número 22; (b) realce de contraste com o filtro CLAHE; (c) imagem com as estruturas escuras destacadas; (d) imagem de saída do método de detecção, onde é destacada uma área que foi incorretamente mantida devido a problemas de iluminação.

Em contrapartida, o método obteve resultados interessantes na terceira etapa - detecção dos vasos sanguíneos, alcançando uma boa precisão através da solução apresentada, baseada na soma de aberturas morfológicas e na posterior reconstrução da cadeia de vasos, podendo ser considerada uma das principais contribuições deste trabalho.

Para que o método alcançasse um equilíbrio entre os valores de sensibilidade e especificidade, a detecção dos vasos sanguíneos foi submetida a uma análise denominada curva ROC (*Receiver Operating Characteristic*). A curva ROC é um gráfico que mostra a sensibilidade em função do complemento da especificidade para diferentes pontos de corte (GAMEZ, 2013). Cada ponto na curva ROC representa um par sensibilidade/especificidade correspondente a uma decisão de ponto de corte. Um teste com um ponto de corte perfeito tem uma curva ROC

atingindo o canto superior esquerdo do gráfico, denotando 100% de sensibilidade e 100% de especificidade (GAMEZ, 2013). De acordo com Zweig & Campbell (1993), quanto mais próxima a curva ROC está do canto superior esquerdo maior é a precisão do teste. A Figura 5.7 exemplifica algumas curvas ROC, juntamente com suas classificações.




Fonte: Silva, 2004.

Nos testes realizados, os pontos de corte foram definidos como os possíveis tamanhos (em pixels) do elemento estruturante linear utilizado nas aberturas morfológicas para a detecção dos vasos (Equação 4.9). A partir dos diferentes pontos de corte elencados, verificou-se, através da curva ROC, que o tamanho de 40x proporcionou um melhor balanço entre os valores de sensibilidade e especificidade, aproximando a curva ao canto superior esquerdo do gráfico. A Tabela 5.4 mostra os tamanhos em pixels (pontos de corte) que foram testados para o elemento estruturante, demonstrando os respectivos valores de sensibilidade e especificidade alcançados pelo método. A Figura 5.8 mostra a curva ROC gerada utilizando-se todos os elementos estruturantes mostrados na Tabela 5.4.

Tabela 5.4 – Pontos de corte para a curva ROC

Tamanho do elemento estruturante	Sensitividade	Especificidade
1 px	28,30%	97,27%
10 px	42,61%	95,19%
20 px	79,86%	93,72%
40 px	87,69%	92,44%
60 px	88,79%	90,59%
80 px	89,41%	87,70%
100 px	89,82%	83,64%
150 px	90,57%	79,24%
180 px	90,57%	79,24%

Figura 5.8 – Curva ROC



Além da detecção dos vasos sanguíneos, o método também obteve um bom desempenho em outras etapas. O destaque das estruturas escuras, excetuando a questão das diferenças de iluminação, foi bem sucedido, ao passo que as áreas do disco óptico e das lesões brancas não afetaram significativamente os resultados. Devido sua complexidade relativamente baixa, o método também obteve resultados

atraentes quanto ao seu tempo de execução, analisando cada imagem com cerca de cinco segundos de processamento, ao ser testado numa máquina com o processador Intel Core 2 Duo (2.20 GHz) com 3 GB de RAM. Este fato pode ser um diferencial do método para propósitos de processamento em larga escala de imagens de fundo do olho. A Tabela 5.5 compara o tempo médio de processamento do método proposto com outros trabalhos da literatura.

Tabela 5.5 – Tempo médio de processamento por imagem

Autor	Média por imagem	Ferramenta	Tamanho das imagens (pixels)	Máquina
Niemeijer et al. (2005)	15 minutos	Não descrito	768 x 576	Máquina de 1.7GHz, Processador Intel Pentium IV
Ravishankar et al. (2009)	20 segundos	Não descrito	768 x 576	Máquina de 2 GHz, 448 MB de RAM
Esmaeili et al. (2010)	3 minutos	MATLAB	Não descrito	Máquina de 1.8 GHz
Kande et al. (2010)	35 segundos	MATLAB	512 x 512	Processador Intel Pentium IV
Bagesteiro (2013)	19 segundos	MATLAB	640 x 480	Máquina de 2.1 GHz, Processador Intel Pentium Dual-Core
Hatanaka et al. (2008)	10 segundos	Intel C++ Compiler	640 x 640	Processador Intel Core 2 Duo 2.16 GHz, 1.5 GB de RAM
Este trabalho	5 segundos	MATLAB	640 x 480	Processador Intel Core 2 Duo 2.2 GHz, 3 GB de RAM

6 CONCLUSÃO

Este trabalho apresentou um novo método para detecção automatizada de lesões vermelhas em imagens de fundo do olho.

Conforme exposto nos capítulos iniciais, o aparecimento dessas lesões na retina se caracteriza como o primeiro sinal da retinopatia diabética, uma complicação oriunda do diabetes que afeta cada vez mais pessoas no mundo ocasionando deficiências visuais irreparáveis. A partir das previsões alarmantes da Organização Mundial da Saúde, sobre o crescimento expressivo dos casos de diabetes nos próximos anos, tornam-se necessárias medidas por parte dos governos para a triagem em massa de populações diabéticas. Essas ações permitiriam o acompanhamento dos pacientes diabéticos periodicamente, uma vez que a evolução do diabetes tende a causar a retinopatia diabética. Neste contexto se encaixa um sistema de detecção automatizada de microaneurismas e hemorragias, sendo capaz de identificar essas lesões com mais agilidade do que a inspeção manual realizada por um oftalmologista. Além disso, tais sistemas possibilitariam o processamento de um grande volume de imagens, utilizando para este fim imagens da retina captadas de uma forma não invasiva.

Na revisão de literatura deste trabalho foram apresentados resumos de publicações atuais, onde foi possível identificar características em comum entre os métodos propostos, além de problemas recorrentes enfrentados pelos autores. A partir dos trabalhos relacionados, constatou-se que várias obras basearam seus métodos em técnicas de morfologia matemática, evidenciando o potencial desta área para a extração de objetos em imagens. Assim realizou-se um estudo sobre os operadores e transformações principais de morfologia matemática aplicados a imagens em tons de cinza.

No capítulo de materiais e métodos foi apresentada a base de dados pública de imagens de fundo do olho DIARETDB1, a qual foi utilizada nos experimentos realizados nesta pesquisa. Logo após, o método de detecção de lesões vermelhas proposto neste trabalho foi apresentado, o qual é baseado num algoritmo de cinco etapas, que resumidamente refina a imagem até obter o conjunto de lesões.

Por fim, no capítulo de discussão e resultados experimentais, apresentaram-se os resultados obtidos pelo método de detecção quando aplicado ao conjunto de imagens provido pelo DIARETDB1. O método alcançou uma sensibilidade média de

87.69% e uma especificidade média de 92.44% em imagens da retina com incidência de lesões. As principais deficiências do método foram explanadas, e podem servir como objeto de estudo para o aprimoramento do algoritmo.

A principal contribuição deste trabalho para o estado da arte está centrada na detecção dos vasos sanguíneos, onde foi apresentada uma solução baseada na soma de aberturas morfológicas e na posterior reconstrução por dilatação das linhas de vasos sanguíneos.

Este trabalho foi publicado como artigo científico no periódico internacional IJCSIT (*International Journal of Computer Science and Information Technology*), v. 5, n. 5, p. 21-37, out. 2013, com os ISSNs 0975-3826 (versão online) e 0975-4660 (versão impressa).

De um modo geral, o método de detecção obteve resultados satisfatórios na maioria das imagens e alcançou medidas de sensibilidade e especificidade equiparáveis aos demais métodos da literatura. Como trabalhos futuros, serão desenvolvidos métodos para detecção de outras lesões relacionadas à retinopatia diabética e outras doenças que afetam a retina.

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, December 2010.
- ALBUQUERQUE, L. **O que é a retinopatia diabética?**. Disponível em: < <http://www.institutoprovisao.com.br/diabetes.html/>>. Acesso em: 12 jun. 2013.
- AMERICAN DIABETES ASSOCIATION. Economic Costs of Diabetes in the U.S. in 2002. **Diabetes Care**, [s. L.], p. 917-932, March 2003.
- BABA et al. Importance of Fluorescein Angiographic Study in Evaluating Early Retinal Changes in Takayasu Disease. **Japanese Journal of Ophthalmology**, [s. L.], v. 43, n. 6, p. 546-552, November 1999.
- 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.
- BAGESTEIRO, L. **Deteção de Lesões Vermelhas em Imagens de Fundo do Olho**, 2013, Trabalho de Conclusão de Curso, Universidade Federal do Pampa, Alegrete.
- 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, September 2003.
- DEVARAJ, D.; NAGAVEENA. Detection Of Red Lesion In Diabetic Retinopathy Using Adaptive Thresholding Method. **International Journal of Engineering Research & Technology (IJERT)**, [s. L.], v. 2, n. 4, p. 1889- 1892, April 2013.
- 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.

GAMEZ, C. **Using the Receiver Operating Characteristic (ROC) curve to analyze a classification model.** Disponível em: <<http://www.math.utah.edu/~gamez/files/ROC-Curves.pdf>>. Acesso em: 19 out. 2013.

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.

GONZALES, C. G.; WOODS, R. E. **Processamento de Imagens Digitais.** São Paulo: Blucher, 2000.

HATANAKA et al. Improvement of Automated Detection Method of Hemorrhages in Fundus Images. In: 30th Annual International IEEE EMBS Conference, 30., 2008, Vancouver. **Proceedings...** Vancouver: IEEE, 2008. p. 5429 - 5432.

IOFS – Instituto de Oftalmologia Faxinal. **Retinografia e Angiografia Fluoresceínica.** Disponível em: <<http://www.iofs.com.br/exames/83/retinografia-e-angiografia-fluoresceinica>>. Acesso em: 12 jun. 2013.

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.

JÄHNE, B.; HAUBECKER, H.; GEIBLER, 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, August 2010.

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

LEE et al. Comparison of Diagnosis of Early Retinal Lesions of Diabetic Retinopathy Between a Computer System and Human Experts. **Arch Ophthalmol**, [s. L.], v. 119, n.4, p. 509-515, April 2001.

LOTTEN EYES. **O que é Retinografia.** Disponível em: <<http://www.lotteneyes.com.br/exames-retinografia/>>. Acesso em: 12 jun. 2013.

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, April 2008.

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, May 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&rastror=PESQUISAS+E+ESTAT%C3%8DSTICAS%2FConceitos+Estat%C3%ADsticos/Sensibilidade+e+Especificidade>. Acesso em: 20 jul. 2013.

PTB – Programa Telessaúde Brasil. **Abordagem Diagnóstica**. Disponível em: <<http://www.telessaudebrasil.org.br/apps/calculadoras/?page=1>>. Acesso em: 20 jul. 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.

ROYCHOWDHURY et al. Screening Fundus Images for Diabetic Retinopathy. In: Conference Record of the Forty Sixth Asilomar, 46., 2012, Pacific Grove. **Proceedings...** Pacific Grove: IEEE, 2012. p. 1641–1645.

SALEH, D; ESWARAN, C. An automated decision-support system for non-proliferative diabetic retinopathy disease based on MAs and HAs detection. **Computer Methods and Programs in Biomedicine**, [s. L.], v. 11, n. 1, p. 186-196, October 2012

SERRA, J. **Image Analysis and Mathematical Morphology**. Londres, Academic Press, Inc., 1982.

SHAHIN et al. Automated Detection of Diabetic Retinopathy in Blurred Digital Fundus Images. In: Computer Engineering Conference (ICENCO), 8., 2012, Cairo. **Proceedings...** Cairo: IEEE, 2012. p. 20-25.

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.

SILVA, A. C. **Algoritmos para Diagnóstico Assistido de Nódulos Pulmonares Solitários em Imagens de Tomografia Computadorizada**. 2004. 140 f. Tese (Doutorado) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2004.

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

SONKA et al. **Image Processing, Analysis, and Machine Vision**. Stamford: Cengage Learning, 2008.

SUJITHKUMAR, B; SINGH V. Automatic Detection of Diabetic Retinopathy in Non-dilated RGB Retinal Fundus Images. **International Journal of Computer Applications**, [s. L.], v. 47, n. 19, p. 26-32, June 2012.

WALTER et al. Automatic detection of microaneurysms in color fundus images. **Medical Image Analysis**, [s. L.], v. 11, n. 6, p. 555-566, December 2007.

WANGENHEIN, A. V. **Morfologia Matemática**. Disponível em: <<http://www.inf.ufsc.br/~visao/morfologia.pdf> >. Acesso em: 12 jun. 2013.

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, July 2010.

WORLD HEALTH ORGANIZATION; INTERNATIONAL DIABETES FEDERATION. **Diabetes**. Disponível em: <<http://www.who.int/mediacentre/factsheets/fs312/en/index.html> >. Acesso em: 12 jun. 2013.

ZHAO et al. Edge Detection Based on Multi-Structure Elements Morphology. In: 6th World Congress on Intelligent Control and Automation, 6, 2006, Dalian. **Proceedings...**Dalian: IEEE, 2006, p. 9795- 9798

ZWEIG M.H.; CAMPBELL G. Receiver-operating characteristic (ROC) plots: a fundamental evaluation tool in clinical medicine. **Clinical Chemistry**, [s. L.], v. 39, n. 4, p.561-577, April 1993.

APÊNDICE A – Resultados da detecção em imagens com lesões

Imagem	SE	ES	VP	FN	FP	VN
1	0,806897	0,905285	234	56	29069	277841
2	0,972414	0,925274	141	4	22945	284110
3	0,927579	0,937255	935	73	19212	286980
4	0,924242	0,926408	671	55	22554	283920
5	0,843589	0,880178	5086	943	36087	265084
6	0,960486	0,921667	316	13	24038	282833
7	0,813506	0,939084	3638	834	18441	284287
8	0,932688	0,917201	4628	334	25025	277213
9	0,851477	0,926085	1009	176	22619	283396
10	0,902408	0,925391	4947	535	22511	279207
11	0,839567	0,929774	3569	682	21275	281674
12	0,968085	0,94457	91	3	17023	290083
13	0,882058	0,94989	703	94	15354	291049
14	0,807124	0,910939	3059	731	27022	276388
15	0,863984	0,91856	2147	338	24816	279899
16	0,746244	0,903432	5514	1875	28952	270859
17	0,91198	0,922172	373	36	23877	282914
18	0,944123	0,947138	1470	87	16157	289486
19	0,83166	0,893365	3231	654	32344	270971
20	0,84211	0,898802	8987	1685	30008	266520
21	0,894059	0,912599	5418	642	26320	274820
22	0,860678	0,912357	6678	1081	26244	273197
23	0,927832	0,938134	3137	244	18796	285023
24	0,919811	0,907817	2340	204	28084	276572
25	0,74191	0,919232	3691	1284	24410	277815
26	0,715977	0,897157	4172	1655	30994	270379
27	0,879298	0,902916	1253	172	29686	276089
29	0,86428	0,871434	1159	182	39323	266536
30	1	0,943475	11	0	17364	289825
32	1	0,952681	9	0	14536	292655
35	0,983871	0,941326	244	4	18010	288942
36	0,943503	0,93017	334	20	21427	285419
37	1	0,933489	3	0	20432	286765
41	0,93617	0,94547	748	51	16708	289693
42	0,946429	0,953469	212	12	14284	292692
43	0,883333	0,932649	106	14	20682	286398
44	0,777108	0,94727	129	37	16190	290844
45	1	0,951881	23	0	14781	292396
52	0,891566	0,940362	296	36	18301	288567
53	0,918269	0,941554	573	51	17918	288658
54	0,522124	0,938998	118	108	18726	288248
55	0,888889	0,94698	784	98	16241	290077
58	0,865801	0,93028	200	31	21402	285567
63	0,923948	0,947939	571	47	15961	290621
64	0,766684	0,931499	2872	874	20787	282667
65	0,922919	0,930998	2694	225	20996	283285
66	0,919983	0,891995	2104	183	32932	271981
67	0,841459	0,923447	2606	491	23280	280823
84	0,926882	0,849686	1724	136	45897	259443
85	0,721988	0,867097	857	330	40670	265343
86	0,576923	0,937809	75	55	19097	287973
87	0,944444	0,948308	17	1	15879	291303
89	1	0,954515	3	0	13973	293224
Média	0,8769502	0,92448	1809,623	329,7358	23012,45	282048,2

Legenda: SE = sensibilidade; ES = especificidade; VP = verdadeiro positivo; FN = falso negativo; FP = falso positivo; VN = verdadeiro negativo.

APÊNDICE B – Resultados da detecção em imagens sem lesões

Imagem	SE	ES	VP	FN	FP	VN
28	-	0,929411	0	0	21685	285515
31	-	0,952259	0	0	14666	292534
33	-	0,946022	0	0	16582	290618
34	-	0,942917	0	0	17536	289664
38	-	0,936566	0	0	19487	287713
39	-	0,955218	0	0	13757	293443
40	-	0,947158	0	0	16233	290967
46	-	0,942607	0	0	17631	289569
47	-	0,897988	0	0	31338	275862
48	-	0,952552	0	0	14576	292624
49	-	0,946787	0	0	16347	290853
50	-	0,935137	0	0	19926	287274
51	-	0,942979	0	0	17517	289683
56	-	0,932799	0	0	20644	286556
57	-	0,934701	0	0	20060	287140
59	-	0,935339	0	0	19864	287336
60	-	0,949554	0	0	15497	291703
61	-	0,945127	0	0	16857	290343
62	-	0,943076	0	0	17487	289713
68	-	0,923424	0	0	23524	283676
69	-	0,943337	0	0	17407	289793
70	-	0,946794	0	0	16345	290855
71	-	0,946312	0	0	16493	290707
72	-	0,942311	0	0	17722	289478
73	-	0,951663	0	0	14849	292351
74	-	0,950518	0	0	15201	291999
75	-	0,95347	0	0	14294	292906
76	-	0,950085	0	0	15334	291866
77	-	0,951761	0	0	14819	292381
78	-	0,940602	0	0	18247	288953
79	-	0,953197	0	0	14378	292822
80	-	0,949723	0	0	15445	291755
81	-	0,96737	0	0	10024	297176
82	-	0,945508	0	0	16740	290460
83	-	0,954395	0	0	14010	293190
88	-	0,96276	0	0	11440	295760
Média	-	0,944484	0	0	17054,5	290145,5

Legenda: SE = sensibilidade; ES = especificidade; VP = verdadeiro positivo; FN = falso negativo; FP = falso positivo; VN = verdadeiro negativo.