



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA

CRISTIANE DE FÁTIMA DOS SANTOS CARDOSO

**SEGMENTAÇÃO AUTOMÁTICA DO DISCO
ÓPTICO E DE VASOS SANGUÍNEOS EM
IMAGENS DE FUNDO DE OLHO**

Uberlândia, 15 de maio de 2019

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA

CRISTIANE DE FÁTIMA DOS SANTOS CARDOSO

**SEGMENTAÇÃO AUTOMÁTICA DO DISCO
ÓPTICO E DE VASOS SANGUÍNEOS EM
IMAGENS DE FUNDO DE OLHO**

Tese apresentada à Faculdade de Engenharia
Elétrica da Universidade Federal de Uberlân-
dia como parte das exigências para obtenção
do título de Doutor em Ciências.

Orientador(a):
Gilberto Arantes Carrijo

Uberlândia, 15 de maio de 2019

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

C268 2019	<p>Cardoso, Cristiane de Fátima dos Santos, 1982- Segmentação automática do disco óptico e de vasos sanguíneos em imagens de fundo de olho [recurso eletrônico] / Cristiane de Fátima dos Santos Cardoso. - 2019.</p> <p>Orientador: Gilberto Arantes Carrijo. Tese (Doutorado) - Universidade Federal de Uberlândia, Pós-graduação em Engenharia Elétrica. Modo de acesso: Internet. Disponível em: http://dx.doi.org/10.14393/ufu.te. 2019.2072 Inclui bibliografia. Inclui ilustrações.</p> <p>1. Engenharia elétrica. I. Carrijo, Gilberto Arantes, 1948- (Orient.). II. Universidade Federal de Uberlândia. Pós- graduação em Engenharia Elétrica. III. Título. CDU: 621.3</p>
--------------	---

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074



UNIVERSIDADE FEDERAL DE UBERLÂNDIA

ATA DE DEFESA

Programa de Pós-Graduação em:	Engenharia Elétrica				
Defesa de:	Tese de Doutorado, 244, COPEL				
Data:	07/06/2019	Hora de início:	13:30	Hora de encerramento:	15:25
Matrícula do Discente:	11413EEL001				
Nome do Discente:	Cristiane de Fátima dos Santos Cardoso				
Título do Trabalho:	Segmentação automática do disco óptico e de vasos sanguíneos em imagens de fundo de olho				
Área de concentração:	Processamento da informação				
Linha de pesquisa:	Processamento digital de sinais				
Projeto de Pesquisa de vinculação:	COMPRESSÃO DE IMAGENS. Data de Início: 01/01/2001. Natureza do Projeto: PESQUISA. Situação do Projeto: EM ANDAMENTO. Descrição: Uso de técnicas de compressão de imagens tais como transformada vetorial para compressão de imagens estáticas e médicas.				

Reuniu-se no Anfiteatro 1E da Faculdade de Engenharia Elétrica, Campus Santa Mônica, da Universidade Federal de Uberlândia, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Elétrica, assim composta: Professores Doutores: Lacordaire Kemel Pimenta Cury - IFGOIANO, Júlio César Ferreira - IFGOIANO, Antônio Claudio Paschoarelli Viegas - UFU; Milena Bueno Pereira Carneiro - UFU; Gilberto Arantes Carrijo - UFU, orientador(a) do(a) candidato(a).

Iniciando os trabalhos o(a) presidente da mesa, Dr(a). Gilberto Arantes Carrijo, apresentou a Comissão Examinadora e o candidato(a), agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado(a).

Esta defesa faz parte dos requisitos necessários à obtenção do título de **Doutor**.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.

Documento assinado eletronicamente por **Júlio César Ferreira, Usuário Externo**, em 14/06/2019, às 15:13, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Lacordaire Kemel Pimenta Cury, Usuário Externo**, em 14/06/2019, às 15:23, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Gilberto Arantes Carrijo, Professor(a) do Magistério Superior**, em 21/06/2019, às 08:41, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Antonio Claudio Paschoarelli Veiga, Professor(a) do Magistério Superior**, em 21/06/2019, às 10:33, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Milena Bueno Pereira Carneiro, Professor(a) do Magistério Superior**, em 24/06/2019, às 17:32, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1241309** e o código CRC **D7E5CCFF**.

Dedico este trabalho aos meus filhos Laura, Arthur e Heloisa.

AGRADECIMENTOS

Agradeço a todos que contribuíram para a realização deste trabalho. Em especial meus familiares, companheiros do Laboratório de PDS, professora Edna Lúcia Flores que muito me incentivou, professor Gilberto Arantes Carrijo, meu estimado orientador; e os professores: Antônio Cláudio Paschoarelli Veiga, Júlio César Ferreira, Lacordaire Kemel Pimenta Cury e Milena Bueno Pereira Carneiro pelas valorosas contribuições.

Agradeço ao Instituto Federal Goiano, Campus Urutaí, pelo auxílio na forma de afastamento para pós-graduação. Também agradeço aos pesquisadores e instituições que disponibilizaram as bases de dados utilizadas neste trabalho. Agradeço a Beijú, futura cão guia, e sua socializadora Cleide Aparecida da Silva, pelos momentos de descontração na fase final da confecção desta tese.

Agradeço em especial ao meu companheiro e parceiro de todas as horas, Jucelino Cardoso Marciano dos Santos.

Por fim, agradeço ao povo brasileiro e a Deus.

A segmentação eficiente do disco óptico e vasos sanguíneos viabiliza o desenvolvimento de uma gama de ferramentas de diagnóstico em imagens de retina, contribuindo para o diagnóstico médico de patologias como retinopatia hipertensiva, diabética e da prematuridade, glaucoma, lesões por zika vírus, etc. Entretanto, a etapa de segmentação do disco óptico e vasos sanguíneos é considerada por muitos uma das tarefas mais difíceis em processamento de imagens, especialmente em retinografias coloridas, que possuem baixo contraste devido a predominância do vermelho em toda a retina. Assim, o objetivo deste trabalho é segmentar as principais estruturas fisiológicas da retina, sendo elas o disco óptico e os vasos sanguíneos. Para tanto, foi proposto (i) um algoritmo baseado em filtro de energia multiescala e transformada de Hough para localização rápida do disco e critério de decisão, respectivamente; (ii) um algoritmo baseado em *roughness index* 3D combinado com morfologia matemática e uso da representação Anatassov Intuitionistic Fuzzy Set para segmentar o disco óptico; (iii) uma rede neural *multilayer perceptron* em que o diferencial é o ajuste do pré-processamento baseado em *Contrast Limited Adaptive Histogram Equalization* (CLAHE) e filtro de Wiener para segmentar os vasos sanguíneos. Como resultados observa-se que (i) o método de localização do disco alcançou 100% de eficácia nas bases HRF e DRIVE, 98,5% na base Messidor e 94,38% na base DIARETDB1; (ii) na segmentação automática do disco óptico foi obtida uma *accuracy* de 99,59% e *sensitivity* de 91,56% na base Messidor; (iii) em segmentação dos vasos sanguíneos é apresentado um ajuste fino do pré-processamento permitindo um desempenho superior da rede, foi obtida uma *accuracy* de 94,87% para o primeiro observador e 95,31% para o segundo observador na base DRIVE, tais valores superam até mesmo metodologias mais complexas.

Palavras-chave:

Retinografias. Processamento digital de imagem. Segmentação RGB. Filtro de energia. Transformada de Hough. A-IFS Histon. *Roughness Index*.

The efficient segmentation of the optic disc and the blood vessels enables the development of an array of retinal images diagnostic tools, thus contributing for the medical diagnosis of pathologies such as Hypertensive and Diabetic retinopathy, Retinopathy of Prematurity, Glaucoma, retinal lesions caused by the Zika virus, etc. However, the step of segmentation of the optic disc and the blood vessels is considered by many one of the most difficult tasks in image processing, especially in colour fundus photography, which possesses lower contrast due to the prevalence of red in all the retina. Thus, the objective of this work is to segment the main physiological structures of the retina, those being the optic disc and the blood vessels. In order to do so, it was proposed (i) an algorithm based on a multiscale energy filter with a Hough transform to rapidly locate the disc and a decision criterion in the disc location, respectively; (ii) an algorithm based on 3D roughness index combined with mathematical morphology and the use of the Atanassov Intuitionistic Fuzzy Set representation to segment the optic disc; (iii) a multilayer perceptron neural network in which the differential is the setting of the pre-processing step based on Contrast Limited Adaptive Histogram Equalisation (CLAHE) and a Wiener filter to segment the blood vessels. As for results, it is observed that (i) the disc location method achieved 100% effectiveness with the HRF and DRIVE databases, 98,5% with the Messidor database and 94,38% with the DIARETDB1 database; (ii) in the automatic segmentation of the optic disc with the Messidor database the accuracy achieved was of 99,59% and the sensitivity was of 91,56%; (iii) in the segmentation of the blood vessels, it is possible to fine-tune the pre-processing step allowing for a superior network performance; it was obtained an accuracy of 94,87% for the first observer, and 95,31% for the second observer in the DRIVE database, such figures exceed even more complex technologies.

Key-words:

Fundus images. Digital Image Processing. RGB Segmentation. Energy filter. Hough Transform. A-IFS Histon. *Roughness Index*.

LISTA DE FIGURAS

2.1	Visão Humana	19
2.2	Olho Humano	20
2.3	Divisão das áreas do disco óptico.	21
2.4	Exames oftalmológicos por fotografia do fundo do olho.	23
2.5	Retinógrafo digital	24
2.6	Sinais oculares	26
2.7	Outros sinais oculares	26
2.8	Causas de cegueira no mundo	27
3.1	Passos fundamentais em processamento digital de imagens	30
3.2	Máscara delimitando a FOV	32
3.3	Representação da relação entre os pixels da imagem segmentada e do ground truth.	33
3.4	Imagens da base DIARETDB1.	36
3.5	Imagens da base DRIVE.	37
3.6	Imagens da base HRF.	38
3.7	Graus de retinopatia na base Messidor.	39
3.8	Imagens da base STARE.	40
3.9	Imagem RGB e seu histograma	43
3.10	Histon de imagem RGB	44
3.11	Rough Set	47
3.12	Algoritmo de segmentação por <i>roughness index</i>	54
4.1	Geração do histograma 3D, histon 3D e fuzzy histon 3D. Adaptado de Chiranjeevi e Sengupta (2012).	73
5.1	Variação de contraste na base Messidor	77
5.2	Pré-processamento das imagens	79
5.3	Etapas do pré-processamento das imagens em CIE Lab	80
5.4	Etapas do pré-processamento das imagens em RGB	81
5.5	Teste inicial de localização do disco óptico em imagens pré-processadas	81
5.6	Curva de ajuste da luminância	82
5.7	Fluxograma do algoritmo de localização do disco óptico	83
5.8	Adição de máscara para eliminar brilho intenso nas extremidades.	84
5.9	Filtro de energia multiescala na imagem ‘23_training.tif’ da base DRIVE.	85

5.10	Imagem com grande concentração de energia e localização do disco com diferentes tamanhos de bloco.	87
5.11	Análise de cor dos discos da base Messidor	88
5.12	Análise de cor dos discos da base DIARETDB1	88
5.13	Eixo medial e Hough medial	89
5.14	Obtendo o contorno do disco	90
5.15	Hough Medial	91
5.16	Diferença entre distância RGB e distância A-IFS	93
5.17	Imagem original a ser segmentada	94
5.18	Histogramas, Histons e <i>Roughness Index</i> : básico e A-IFS	95
5.19	Vales selecionados por meio do <i>roughness index</i>	96
5.20	Histograma, histons e <i>roughness index</i> : 3D e <i>smoothed</i>	96
5.21	Limiarização com base nos <i>thresholds</i> do <i>rough index</i> básico - HRI	98
5.22	Resultados da segmentação por <i>roughness index</i>	99
5.23	Secção transversal em uma imagem englobando três vasos sanguíneos.	100
5.24	Segmentação por 3DMFHRI	101
5.25	Histograma 3D e Histon 3D	103
5.26	Diagrama da metodologia proposta para segmentar vasos sanguíneos.	105
5.27	Pré-processamento para segmentação dos vasos sanguíneos	106
6.1	Resultado da segmentação do disco óptico.	114
6.2	Resultado da segmentação dos vasos sanguíneos	119
A.1	Modelos de cores.	139
A.2	Modelos de cores e dispositivos	139
A.3	Modelo de cores HSI	140
B.1	Recorte de Disco óptico (D) contendo escavação (E)	143
B.2	Retinopatia diabética não proliferativa.	144
B.3	Alterações da visão na retinopatia diabética.	145
B.4	Estágios da retinopatia diabética.	145

LISTA DE TABELAS

3.1	Resultado da segmentação em comparação com a segmentação feita por um especialista.	32
3.2	Classificação dos níveis de DR na base Messidor	39
3.3	Classificação dos níveis de risco de edema macular na base Messidor	39
5.1	Uso de bases públicas de imagens pelo presente trabalho	77
6.1	Taxa de acerto na localização do disco óptico	111
6.2	Comparação dos resultados entre os diferentes tipos de <i>roughness index</i> , em segmentação automática e semi-automática.	112
6.3	Comparação do método proposto com outros métodos na literatura. Fonte: adaptada de Al-Bander et al. (2018)	113
6.4	<i>Accuracy</i> em função do número de neurônios na camada oculta.	115
6.5	Resultados no conjunto TEST da base DRIVE para o primeiro e o segundo observador	116
6.6	Comparação do método proposto com outros métodos do estado da arte - base DRIVE.	118
6.8	Comparativo da <i>Overlapping score</i> na base Messidor	120
B.1	Características da neovascularização (DORION, 2002)	144

LISTA DE ABREVIATURAS E SIGLAS

- 3DMFHRI *3D Morphologic Fuzzy Histon Roughness Index*. Pag.95
- 3DMHRI *3D Morphologic Histon Roughness Index*. Pag.95
- A-IFS *Atanassov's Intuitionistic Fuzzy Set*. Pag.50
- Acc *Accuracy*. Pag.36
- ACM *Active Contour Model*. Pag.62
- ANN *Artificial Neural Network*. Pag.62
- ASM *active shape model*. Pag.61
- AUC *Area Under the Curve*. Pag.36
- CDC *Centers for Disease Control Prevention*. Pag.17
- CIE *Comission Internationale de l'Eclairage – Comissão Internacional de Iluminação*. Pag.142
- CLAHE *Contrast Limited Adaptive Histogram Equalization*. Pag.69
- CMYK *Cyan, Magenta, Yellow, Black* – ciano, magenta, amarelo, preto. Pag.140
- CNN *Convolutional Neural Network*. Pag.65
- CWNO *Column Wise Neighborhood Operation*. Pag.69
- dd *disco de distância*. Pag.24
- DIARETDB1 *DIAbetic RETinopathy DataBase*. Pag.37
- DR *Diabetic Retinopathy*. Pag.145
- DRIVE *Digital Retinal Images for Vessel Extraction*. Pag.39
- DSM *Dice Similarity Measure*. Pag.37
- F *F-score*. Pag.37
- FCM *fuzzy c-mean*. Pag.62

FN *False negative*. Pag.34

FOV *Field Of View*. Pag.33

FP *False positive*. Pag.34

FPR *False Positives Ratio*. Pag.35

GVF *gradient vector flow*. Pag.61

H **Hemorragias**. Pag.27

HRF *High Resolution Fundus*. Pag.39

HSI *Hue, Saturation, Intensity* – matiz, saturação, intensidade. Pag.140

IRMA **Anormalidades microvasculares intra-retinianas**. Pag.27

kNN regressor *k-Nearest Neighbors regressor*. Pag.60

LGN *lateral geniculate nucleus*. Pag.21

LNNDP *Lattice Neural Network with Dendritic Processing*. Pag.65

LPR *Local Polynomial Regression*. Pag.70

MA *Microaneurysms*. Pag.26

MAT *Medial Axis Transform*. Pag.68

NCO Neurônios na Camada Oculta. Pag.110

NPDR *No Proliferative Diabetic Retinopathy* - retinopatia diabética não proliferativa. Pag.41

NV **Neovascularização**. Pag.27

OD **Optic Disc- Disco óptico**. Pag.23

PCA *Principal Components Analysis*. Pag.59

PDR *Proliferative Diabetic Retinopathy* - retinopatia diabética proliferativa. Pag.40

PPA *peripapillary atrophy*. Pag.58

RGB *Red, Green, Blue* – vermelho, verde, azul. Pag.140

ROC *Receiver Operating Characteristic*. Pag.36

ROP retinopatia da prematuridade. Pag.145

S *Overlapping score*. Pag.37

SLIC *Simple Linear Iterative Clustering*. Pag.60

SN *sensitivity*. Pag.36

SP *especificity*. Pag.36

STARE *STructered Analysis of the REtina*. Pag.41

SVM *Support Vector Machine*. Pag.65

TAN *Topological Active Nets*. Pag.61

TN *True negative*. Pag.34

TP *True positive*. Pag.34

TPR *True Positives Ratio*. Pag.35

WHO *World Health Organization*. Pag.16

ZCA *Zero-phase Component Analysis*. Pag.77

d1 *distância euclidiana em imagens coloridas*. Pag.95

d2 *distância euclidiana em imagens A-IFS*. Pag.95

Fhist *Fuzzy histogram*. Pag.95

FHiston *Fuzzy Histon*. Pag.95

FHRI *Fuzzy Histon Roughness Index*. Pag.95

hist *histograma*. Pag.95

Histon *histon*. Pag.95

HRI *Histon Roughness Index*. Pag.95

SFhist *Smoothed Fuzzy HISTogram*. Pag.95

SFHiston *Smoothed Fuzzy HISTON*. Pag.95

SFHRI *Smoothed Fuzzy Histon Roughness Index*. Pag.95

Shist *Smoothed HISTogram*. Pag.95

SHiston *Smoothed HISTON*. Pag.95

SHRI *Smoothed Histon Roughness Index*. Pag.95

1	INTRODUÇÃO	13
1.1	Justificativa	14
1.2	Objetivos	16
1.2.1	Objetivos Específicos	16
1.3	Estrutura do trabalho	16
2	FUNDAMENTOS EM OFTALMOLOGIA	18
2.1	A visão humana	18
2.1.1	O olho humano	19
2.2	Exame de fundo de olho	22
2.3	Sinais oculares	23
2.4	Doenças da retina	27
2.5	Considerações finais do capítulo	27
3	FUNDAMENTOS TEÓRICOS GERAIS	29
3.1	Processamento, análise, reconhecimento e segmentação de imagens	29
3.2	Métricas para a avaliação da segmentação de Imagens	31
3.3	Base de dados de Imagens	35
3.4	Transformada de Hough	40
3.5	Histograma	41
3.6	Histon	43
3.7	Teoria dos conjuntos aproximativos	45
3.7.1	Atanassov's <i>Intuitionistic Fuzzy Set</i> (A-IFS)	48
3.8	Segmentação por <i>Roughness Index</i>	50
3.9	Considerações finais do capítulo	54
4	ESTADO DA ARTE	56
4.1	Segmentação do disco óptico	56
4.1.1	Localização do disco óptico	57
4.1.2	Delimitação do disco óptico	59
4.2	Segmentação dos vasos sanguíneos	60
4.2.1	Segmentação dos vasos sanguíneos por rastreamento	61
4.2.2	Segmentação dos vasos sanguíneos por modelos - <i>matched filtering</i>	61

4.2.3	Segmentação dos vasos sanguíneos por classificação supervisionada de pixels	62
4.2.4	Segmentação dos vasos sanguíneos por modelos deformáveis	64
4.2.5	Segmentação dos vasos sanguíneos por morfologia matemática	65
4.2.6	Segmentação dos vasos sanguíneos por outros métodos e considerações gerais	65
4.3	Trabalhos correlatos	66
4.3.1	Trabalhos correlatos em localização do disco óptico	66
4.3.2	Trabalhos correlatos em segmentação do disco óptico	66
4.3.3	Trabalhos correlatos em segmentação dos vasos sanguíneos	74
4.4	Considerações finais do capítulo	74
5	MÉTODOS PROPOSTOS	76
5.1	Aquisição de imagens	76
5.2	Pré-processamento	77
5.3	Localização do disco óptico	82
5.3.1	Pré-processamento para localização do disco óptico	83
5.3.2	Localização rápida	84
5.3.3	Localização precisa	88
5.4	Segmentação do disco óptico	91
5.4.1	Variações em <i>roughness index</i>	92
5.4.2	Matriz distância	93
5.4.3	Histogramas, histons e <i>roughness index</i>	94
5.4.4	Segmentação por meio do <i>roughness index</i> clássico	97
5.4.5	3D Morphologic Fuzzy Histon Roughness Index (3DMFHRI)	99
5.5	Segmentação dos vasos sanguíneos	104
5.5.1	Estágio B - pré-processamento	104
5.5.2	Estágio C - treinamento da RNA	106
5.5.3	Estágio D - pós-processamento	108
5.6	Considerações finais deste capítulo	108
6	RESULTADOS	110
6.1	Resultados em localização do disco óptico	110
6.2	Resultados em segmentação do disco óptico	111
6.3	Resultados em segmentação dos vasos sanguíneos	115
6.4	Discussão	120
6.4.1	Considerações sobre a localização e segmentação do disco óptico . . .	120
6.4.2	Considerações sobre a segmentação dos vasos sanguíneos	121
	CONCLUSÃO	123
A	Apêndice - IMAGENS E MODELOS DE CORES	138
B	Apêndice - GLAUCOMA E RETINOPATIA DIABÉTICA	142
B.1	Glaucoma	142
B.2	Retinopatia diabética	143

CAPÍTULO 1

INTRODUÇÃO

Em processamento digital de imagens, uma das tarefas mais difíceis de ser realizada é a segmentação, raramente uma técnica apresenta bom desempenho em todos os contextos, isso se observa particularmente nas situações em que não há controle sobre o ambiente e os sensores de captura. Segmentação é a tarefa de dividir uma imagem em diversas partes sem que haja sobreposição; ela pode ser realizada com base em propriedades de intensidade ou morfologia, no primeiro caso tem-se abordagens baseadas em descontinuidade e similaridade. Como métodos baseados em descontinuidade tem-se a detecção de bordas, linhas e pontos, já os métodos baseados em similaridade são orientados a subdivisão em regiões e incluem limiarização, divisão/fusão de regiões, dentre outros. Métodos baseados em morfologia são muito utilizados e incluem *Watershed*, *active shape model* etc, essa categoria possui a vantagem de ser estável e produzir fronteiras mais precisas (GONZALEZ; WOODS, 2010).

Tendo em vista que nenhuma técnica é universal em segmentação, o estudo e melhoria de qualquer técnica é benéfico, e muitas vezes isso é feito dentro de um domínio de problema, no presente caso, foram escolhidas as retinografias coloridas disponíveis em bases públicas. Em uma retinografia observa-se a presença do disco óptico, vasos sanguíneos, mácula e fóvea, e possivelmente sinais oculares decorrentes de patologias.

O número de doenças que afetam a retina e seus elementos é considerável e um mesmo sinal ocular pode ser sugestivo de diversas doenças, por exemplo, a tortuosidade dos vasos é um sintoma da retinopatia diabética e também da retinopatia hipertensiva (DORION, 2002). Assim, conceber um sistema especialista que seja capaz de realizar o diagnóstico automático ou semi-automático de todas essas doenças é quase impraticável, de forma que os pesquisadores optam

sempre por identificar uma patologia provendo sistemas que detectam os sinais oculares relativos a ela. Qualquer que seja a patologia a ser diagnosticada, é necessário realizar a segmentação da imagem, assim, algo extremamente útil é prover métodos que sejam o ponto de partida em qualquer sistema de detecção de doenças e até mesmo de biometria em imagens de fundo de olho. Por isso, este trabalho se propõe a realizar a segmentação dos elementos fisiológicos do olho em retinografias, particularmente o disco óptico e os vasos sanguíneos, sendo que diferentes possibilidades podem ser atingidas a partir de cada elemento segmentado ou localizado: a partir da localização do disco óptico, pode ser feita a segmentação do mesmo ou dos vasos sanguíneos e a localização da mácula e da fóvea. Já a segmentação do disco óptico é primordial para qualquer técnica que vise diagnosticar lesões, seja no próprio disco ou na retina. Dentre as doenças que causam lesões no disco tem-se o glaucoma, papiledema, neovascularização do disco, anomalias do disco óptico, mielinização das fibras nervosas, avulsão do disco óptico, hemorragias do disco, etc (DORION, 2002), (LYSTAD et al., 2008), (CHRÁSTEK et al., 2005), (CHENG et al., 2013), (FUENTE-ARRIAGA et al., 2014), (ACHARYA et al., 2015). A segmentação dos vasos sanguíneos é importante em sistemas que reconheçam problemas como retinopatia diabética, retinopatia hipertensiva, retinopatia da prematuridade, oclusão de artéria retiniana, doenças que causam neovascularização em geral, dentre outros (MARTINEZ-PEREZ et al., 2007), (MURAMATSU et al., 2011b).

Xie et al. (2015) falam sobre a dificuldade em segmentar imagens médicas, que muitas vezes são ruidosas, possuem variação intrínseca de tecidos, efeitos de volume parcial, limites de tecido pouco nítidos e intensidade não uniforme. Em imagens de fundo de olho observa-se alguns desses efeitos, sendo que o principal problema é a baixa separabilidade entre as estruturas demandando aprimoramento e estudo de técnicas apropriadas (MOOKIAH et al., 2013c). Com isso, espera-se uma grande contribuição deste trabalho para os futuros sistemas de diagnóstico automático em imagens de fundo de olho, que tem sido cada vez mais demandados. Em relação a retinografias a principal demanda é quanto a retinopatia diabética, uma vez que todo diabético deve realizar este exame periodicamente.

1.1 Justificativa

Conforme *World Health Organization* (WHO), a capacidade visual das pessoas pode ser classificada como: visão normal, deficiência visual moderada, deficiência visual grave e cegueira. De forma simplificada, baixa visão designa casos de deficiência visual moderada e grave (WHO,

2010). Em seus relatórios a WHO afirma que existem 285 milhões de pessoas com deficiência visual em todo o mundo, deste total, 39 milhões são cegos e 246 milhões apresentam baixa visão, sendo que 80% dos casos de deficiência visual podem ser evitados ou curados (WHO, 2014). Assim, é importante viabilizar o tratamento destes pacientes e o primeiro passo é um diagnóstico preciso, que seja confiável e ao mesmo tempo de baixo custo.

Uma alternativa altamente viável e eficiente é o diagnóstico por meio de processamento de imagens digitais, e para isso, as imagens devem ser submetidas a uma série de operações agrupadas por etapas, a principal delas é a segmentação. Conforme foi dito anteriormente, o objetivo da segmentação é dividir a imagem em partes entregando algo significativo e fácil de analisar para as etapas seguintes, que vão culminar em métodos de classificação, daí se percebe a importância de uma segmentação bem feita. Não se pode classificar corretamente algo que não representa o que de fato é. O diagnóstico automático ou semiautomático de diversas doenças em oftalmologia passam pela segmentação e dentre elas pode-se citar: degeneração macular relacionada a idade, glaucoma, retinopatia diabética, retinopatia da prematuridade e até mesmo a catarata (GUO et al., 2015).

Uma das doenças que requerem maior atenção e acompanhamento é a diabetes, e uma de suas principais complicações é a retinopatia diabética, que quando não tratada pode levar à cegueira. Segundo Hendrick et al. (2015) 99% dos pacientes com diabetes tipo 1 e 60% dos pacientes com diabetes tipo 2 possuem algum grau de retinopatia após 20 anos de diagnóstico da doença. Assim, uma recomendação fundamental a estes pacientes é que façam exames de avaliação do fundo de olho no mínimo anualmente. Em função disso e do fato que o número de diabéticos cresce vertiginosamente, a demanda por este tipo de exame é crescente, os diabéticos estão em constante triagem de retinopatia diabética (KÖSE et al., 2012). Só nos Estados Unidos, em 2012 haviam 21,3 milhões de diabéticos, o *Centers for Disease Control Prevention* (CDC) prevê ainda que em 2050, um em cada 3 norte americanos desenvolverá a diabetes (Centers for Disease Control Prevention, 2014). Em grande parte dos países, os exames para diagnosticar a retinopatia diabética são realizados manualmente (ZAKI et al., 2016), o que causa um grande dispêndio de tempo e dinheiro (KUMAR et al., 2012; ZAKI et al., 2016). Quando detectada e tratada a tempo a retinopatia diabética não deixa qualquer sequela, sendo que o tratamento é feito por laser ou injeções com medicamentos no olho afetado.

Além disso, outra importante justificativa para o trabalho em questão é que assim como a diabetes outras doenças requerem acompanhamento por meio de retinografias. Quanto à análise

manual delas, é interessante notar a subjetividade nas análises de especialistas, o que resulta em diferentes diagnósticos para uma mesma retina (BUDAI et al., 2012). Com isso, técnicas de processamento automático podem vir a se tornar uma alternativa de mais baixo custo e maior confiabilidade do que a análise manual.

1.2 Objetivos

O objetivo geral deste trabalho é implementar e melhorar técnicas de segmentação de imagens de fundo de olho com ênfase no disco óptico e vasos sanguíneos, observando o bom funcionamento nas mais diversas bases de imagens, de forma que os métodos propostos viabilizem futuras aplicações de detecção automática de retinopatia diabética, glaucoma e outras patologias.

1.2.1 Objetivos Específicos

A fim de cumprir com o objetivo geral deste trabalho, diversas tarefas devem ser realizadas, assim, como objetivos específicos tem-se:

- Coletar bases públicas de imagens coloridas de fundo de olho;
- Compreender e descrever as principais características de imagens de fundo de olho coletadas, observando elementos fisiológicos e patológicos;
- Encontrar boas alternativas para pré-processar imagens de fundo de olho;
- Realizar estudo sobre métodos de localização das estruturas fisiológicas da retina em imagens digitais;
- Realizar estudo sobre métodos de segmentação das estruturas fisiológicas da retina em imagens digitais;
- Implementar e propor melhorias nos métodos de localização e segmentação;
- Testar e garantir a confiabilidade dos métodos em um grande número de imagens.

1.3 Estrutura do trabalho

Este trabalho está organizado em 6 capítulos, sendo o primeiro a presente introdução. O capítulo 2 apresenta aspectos em oftalmologia pertinentes ao contexto, para que o leitor possa

compreender as retinografias, a fisiologia da retina e sinais oculares. O capítulo 3 apresenta fundamentos relevantes em processamento de imagens, descrição de bases de dados contendo imagens de retina, e ainda, fundamentos sobre *roughness index* e transformada de Hough circular. O capítulo 4 traz uma revisão do estado da arte em segmentação de imagens do fundo de olho. Já o capítulo 5 apresenta os métodos propostos e o capítulo 6 os resultados obtidos. Por fim é apresentada a conclusão. Assuntos de importância menor foram movidos para o apêndice: um capítulo sobre cores e modelos de cores e outro sobre glaucoma e retinopatia diabética.

CAPÍTULO 2

FUNDAMENTOS EM OFTALMOLOGIA


Este capítulo tem como propósito fornecer conceitos relevantes em oftalmologia. Nas seções seguintes são discutidos aspectos relativos a visão humana, a retinopatia diabética, sinais oculares, dentre outros.

É importante salientar que o nível de informação apresentado é condicionado ao trabalho em questão e por isso não esgota e nem pretende ser um referencial no assunto.

2.1 A visão humana

A visão humana é na verdade um complexo sistema no qual diversos elementos trabalham juntos possibilitando uma ampla percepção do ambiente. Comparativamente, a capacidade de aquisição de imagens por humanos é equivalente a um dispositivo de média resolução (GONZALEZ; WOODS, 2010). Por outro lado, esse sistema conta com uma grande capacidade de processamento que permite interpretar códigos e símbolos, reconhecer objetos e pessoas, e tudo isso em uma fração de segundo. O sistema visual humano possui até mesmo a habilidade de realizar inferências sobre objetos ou cenas incompletas.

A Figura 2.1 ilustra esse complexo sistema que é a visão humana, inicialmente a imagem é captada na retina por células sensíveis a luz, chamadas de fotorreceptores - Figura 2.1(a), sendo dois os tipos: cones que são sensíveis às cores (azul, verde e vermelho) e bastonetes que são sensíveis à luminosidade. Em seguida, estes fotorreceptores transformam os impulsos luminosos em impulsos elétricos e os transmitem às células nervosas que convergem para o nervo óptico, Figura 2.1(b). Este por sua vez adentra o cérebro realizando um cruzamento entre os nervos do olho esquerdo e do direito no quiasma óptico, onde ocorre também a divisão das fibras. Após o

Figura 2.1: Visão Humana**(a) Fonte:** Mental floss¹.**(b) Fonte:** blog Perception of color².**(a)** Olho em corte mostrando projeção da imagem na retina. **(b)** Sistema visual humano.


cruzamento, os impulsos elétricos são levados ao tálamo, mais precisamente ao *lateral geniculate nucleus* (LGN), que funde as imagens dos dois olhos criando a visão estereoscópica e também processa a imagem de maneira rudimentar. Após a passagem pelo tálamo, os impulsos elétricos são levados pelos neurônios até o cortex visual primário, onde as informações são distribuídas a diferentes áreas do cortex visual para serem processadas e reconhecidas, algumas áreas deste cortex são especializadas em reconhecer formas e outras estão mais ligadas à cores (VILIS, 2013).

2.1.1 O olho humano

O olho é um dos elementos mais fantásticos presente nos seres vivos, possui um sistema sofisticado que permite adaptação rápida e sem esforço a ambientes escuros/claros, permite o foco em determinados objetos de interesse ou que se veja o todo. A Figura 2.2 mostra a anatomia do olho humano, destacando-se as partes internas, intermediárias e externas. As principais estruturas do olho são a córnea, o cristalino, a íris, a pupila, a retina, a fóvea, o disco óptico, os vasos sanguíneos e o nervo óptico.

¹Disponível em: <<http://mentalfloss.com/uk/biology/30542/your-eyes-see-everything-upside-down>> acessado em nov. 2015.

²Disponível em: <<http://perceptionofcolor.blogspot.com.br/>> acessado em out. 2015.

Figura 2.2: Olho Humano

Fonte: *Olho humano*³.


Na parte externa estão a esclera e a córnea, que são respectivamente, a parte branca do olho e a parte transparente que recobre a íris. Já a parte intermediária contém a coróide, que é responsável pela nutrição do olho, o corpo ciliar, que é responsável pela produção do humor vítreo e regulação da convexidade do cristalino, e a íris, que protege a retina e dá cor aos olhos (DORION, 2002). A pupila está localizada na íris e funciona de maneira semelhante a um diafragma, abrindo e fechando conforme a luminosidade do ambiente.

Localizada internamente tem-se a retina, que é uma estrutura com uma camada de fotorreceptores e células nervosas. Como foi dito anteriormente, as fibras nervosas que cobrem a retina se juntam no fundo do olho e saem pelo nervo ótico em direção ao cérebro. A cabeça do nervo óptico, também chamada de disco óptico, pode ser visualizada na imagem de fundo do olho como um pequeno círculo claro, e para facilitar sua inspeção, o disco é dividido em parte nasal, temporal, superior e inferior. Os vasos sanguíneos retinianos podem ser observados no fundo do olho, saindo do disco óptico e deslocados para a metade nasal do disco, Figura 2.3 (DORION, 2002).

Os olhos possuem dois tipos de líquidos: humor aquoso e o humor vítreo. O humor aquoso está situado entre a córnea e o cristalino e é constantemente renovado. Já o humor vítreo é o gel que preenche a cavidade posterior do olho.

A Figura 2.4 mostra imagens de fundo de olho na qual se pode perceber diversos elementos, e dentre as estruturas mais importantes para a compreensão deste trabalho destacam-se (MOOKIAH et al., 2013b), (DORION, 2002):

³Disponível em: <<https://olhohumano.wordpress.com/2010/11/05/anatomia-do-olho-humano/>> acessado em out. 2016.

Figura 2.3: Divisão das áreas do disco óptico.

Fonte: Kang⁴.

- **Optic Disc- Disco óptico (OD)** - é o local para onde as fibras nervosas do olho convergem. Trata-se de uma estrutura arredondada ou elipsóide, com cerca de 1,5mm que corresponde a cabeça do nervo óptico. Possui cor rosa a laranja com uma depressão amarelo-pálida no centro (escavação fisiológica do disco óptico). A escavação pode apresentar um pontilhado, o que corresponde a fenestrações da lâmina crivosa e geralmente possui $\frac{1}{3}$ do tamanho do disco. As margens do disco são bem definidas a não ser no lado nasal, devido a grande vascularização. O disco óptico é menor na hipermetropia e maior na miopia.
- **Vasos sanguíneos** - os principais vasos são a veia central e a artéria central retiniana, também pode ocorrer a artéria cilioretiniana. Existem vasos que saem diretamente da artéria central retiniana (vasos retinianos), vasos indiretos (vasos coróides) e capilares. Vasos retinianos não possuem fibras nervosas, entram e saem da retina pelo nervo óptico e bifurcam em ramos superior e inferior, que se dividem em nasal e temporal. As artérias se ramificam em ângulo agudo e na primeira bifurcação geram arteríolas, possuem coloração vermelho clara e um reflexo de luz no centro. As veias possuem pulsação e são mais escuras e largas que as artérias, que estão sobre as veias nos cruzamentos artéria/veia. Vasos coróides não possuem ligação com os vasos retinianos e alimentam a metade externa da retina. Os capilares estão nas camadas ganglionares e superficial da retina e possuem pequeno calibre. Na Figura 2.4(c), à esquerda da letra **A** tem-se uma artéria, enquanto que acima da letra **B** tem-se uma veia.
- **Mácula** - é a área em que se concentram os fotorreceptores, caracterizada como uma leve depressão do pólo posterior, se divide em parafóvea, perifóvea, fóvea e fóveola. A

⁴Disponível em: <https://www.researchgate.net/publication/261257660_Using_ImageJ_to_Evaluate_Optic_Disc_Pallor_in_Traumatic_Optic_Neuropathy> acessado em mai. 2016.

parafóvea é o anel mais externo na mácula, a perifóvea é o anel seguinte, ela possui uma camada de células ganglionares espessa, o próximo anel é a fovea, que é avascular, e por último tem-se a foveola, que é um pequeno buraco no centro da mácula e contém apenas cones, ela concentra mais cones que qualquer outra parte do olho;

- **Fóvea** - a fóvea está localizada na mácula e é uma área importante da retina por concentrar grande parte das células fotorreceptoras, pode ser observada no lado temporal do disco óptico, a uma distância de aproximadamente 2,5 vezes o diâmetro do OD.

Para referenciar o tamanho dos elementos no fundo de olho é comum utilizar a unidade *disco de distância* (dd), em que 1 dd corresponde ao tamanho médio de um disco óptico (1,5mm). Por exemplo, diz-se que o centro da mácula está a 2 dd da margem temporal do disco.


2.2 Exame de fundo de olho

O exame do fundo de olho é uma prática muito importante em consultório médico, uma vez que inúmeras doenças levam a alterações na retina. Uma das maneiras de se realizar este exame é por meio de oftalmoscopia direta, em que um especialista utiliza um oftalmoscópio⁵ para avaliar o disco óptico, os vasos sanguíneos e demais estruturas no fundo do olho. O ambiente deve ser pouco iluminado e é necessário realizar a dilatação da pupila com colírios específicos (DORION, 2002).

Análises mais criteriosas da retina necessitam de métodos mais precisos que a oftalmoscopia direta, para isso, tem-se a angiografia fluoresceínica (Figura 2.4(a)), a fotografia do fundo de olho *red free* (Figura 2.4(b)) e a fotografia colorida-RGB (Figura 2.4(c)). A angiografia fluoresceínica é obtida por meio da aplicação de contraste na corrente sanguínea do paciente, a fotografia *red free* simplesmente descarta ondas do espectro que correspondem ao vermelho, já a fotografia colorida do fundo capta as bandas verde, vermelho e azul (MOOKIAH et al., 2013c).

A fotografia do fundo de olho também é chamada de retinografia digital e pode ser com ou sem dilatação da pupila (midriática ou não midriática).

⁵ Aparelho inventado por Hermann von Helmholtz em 1850 constituído de uma fonte de luz e espelho que projeta a luz no olho do paciente.

Figura 2.4: Exames oftalmológicos por fotografia do fundo do olho.

(a) Angiografia fluoresceínica - **Fonte:** Rabbani et al. (2015). (b) Fotografia *red free* do fundo do olho com retinopatia diabética - **Fonte:** *Ophthalmic Photographer's Society*⁶. (c) Fotografia colorida do fundo de olho normal - **Fonte:** *Fine Eyewear*⁷.

A retinografia digital possui como requisitos de aquisição uma boa resolução, rapidez no foco e captura, controle de iluminação, filtros (por exemplo o de remoção do vermelho), angulação correta (o quê varia de 30° a 45°) e boa operabilidade. Assim, no lugar de uma simples câmera, é utilizado um equipamento designado por retinógrafo digital, que atende a todos estes requisitos. Um exemplo deste tipo de dispositivo é a *TRC-NW8 Non-Mydriatic Retinal Camera* que possui uma resolução de 16.2 megapixel com um ângulo de 45°, Figura 2.5.

2.3 Sinais oculares

Além dos elementos esperados, diversos artefatos (sinais oculares) podem ser observados durante um exame de fundo de olho. As Figuras 2.6 e 2.7 sintetizam os principais sinais oculares levando em consideração as imagens utilizadas neste trabalho. Nem sempre estes achados são relevantes clinicamente, no entanto, uma grande concentração dos mesmos, ou uma certa

⁶Disponível em: <<http://www.opsweb.org/?page=Monochromatic>> acessado em mai. 2016.

⁷Disponível em: <<http://fineeyewear.net/wordpress/archives/156>> acessado em fev. 2016.

Figura 2.5: Retinógrafo digital


Modelo *TRC-NW8 Non-Mydriatic Retinal Camera* . **Fonte:** Topcon⁸.

combinação deles, pode ser indicativo de alguma patologia. Conforme Dorion (2002) e Hendrick et al. (2015), os principais sinais oculares são:


- **Manchas algodinosas** - também conhecidas como exsudatos moles, são microinfartos retinianos resultantes de doenças como: diabetes, hipertensão, oclusão da veia retiniana, papiledema, doenças do colágeno, anemia, leucemia e síndromes de hiperviscosidade. Tais manchas possuem aspecto pálido, geralmente em tons branco-acinzentados, e se diferenciam por possuírem margens borradas e irregulares. Costumam ser encontradas em volta do disco óptico. Estas manchas surgem devido a infartação dos axônios das células ganglionares localizada na camada de fibra nervosa retiniana e parecem ligeiramente elevadas, Figura 2.6(b);
- **Exsudatos duros** - são depósitos lipoprotéicos amarelos-esbranquiçados com aspecto brilhante e margens bem delimitadas. Em retinografia possuem um aspecto refratível e podem aparecer em diversas disposições: isolados, em cachos, em trilhas confluentes ou em anel parcial ou completo. Usualmente, se localizam no pólo posterior, perto ou ao redor da mácula. Podem configurar alguns pontos ou até formarem placas, alguns se dispersam em 4 a 6 meses e outros permanecem por anos, Figura 2.6(c);
- **Microaneurismas** (*Microaneurysms* (MA)) - podem ser vistos na forma de pequenos pontos vermelhos em imagens de retinografias. São lesões em forma sacular que surgem na parede de vasos capilares, Figura 2.6(c);

⁸Disponível em: <<http://www.topconmedical.com/products/trcnw8.htm>> acessado em mai. 2016.

- **Hemorragias (H)** - Podem ocorrer na camada pré-retiniana, na retina, ou no vítreo. Seu aspecto muda conforme o lugar em que ocorre. Hemorragias pré-retinianas costumam ser volumosas e se acumulam em bolsas de formato arredondado semelhante a uma taça, não são provenientes de retinopatia diabética. Hemorragias intra-retinianas são lesões que variam do vermelho ao cinza escuro, são irregulares e com margens bem definidas, elas geralmente desaparecem dentro de 3 a 4 meses, e ocorrem devido a vazamento em vasos capilares, Figura 2.6(d). Hemorragias vítreas ocorrem na cavidade vítrea e causam obscurecimento na visão, Figura 2.7(a);
- **Tortuosidade** - é quando ocorre uma mudança no curso dos vasos retinianos que se tornam mais irregulares e em saca-rolhas. Nos cruzamentos com as artérias, as veias se tornam estreitadas e podem até mesmo assumir uma aparência de corda de salsichas. A tortuosidade pode ser congênita ou decorrente de doenças cardíacas, hipertensão, retinopatia diabética, dentre outras, Figura 2.4(a) e 2.7(b);
- **Anormalidades microvasculares intra-retinianas (IRMA)** - segmentos de microvasos dilatados e tortuosos, geralmente na periferia do disco. Basicamente o que ocorre é que devido ao desvio precoce dos vasos e formação colateral surgem irregularidades no calibre dos mesmos;
- **Edema Macular** - é quando ocorre o vazamento de plasma surgindo o inchaço. Pode acontecer no início do desenvolvimento DR, bem como em decorrência de outros problemas. É caracterizado por uma coloração cinza-esbranquiçada com um reflexo de luz ou com um espaço petalóide como um favo cheio de fluído circundado por cistos menores. No caso de edema macular clinicamente significativo, há um espessamento retiniano - exsudatos duros, próximos ao centro da mácula, muitas vezes apresenta ao lado de microaneurismas, Figura 2.7(b);
- **Neovascularização (NV)** - conforme pode ser observado na Figura 2.7(a), a neovascularização é crescimento anormal de novos vasos sanguíneos, pode ocorrer em mais de uma camada da retina. Os novos vasos possuem paredes fracas gerando sangramentos e microaneurismas;
- **Descolamento de retina** - a neovascularização da retina, além de outros fatores, podem tracionar e separar a retina de sua posição anatômica resultando em descolamento;

Figura 2.6: Sinais oculares

(a) Reflexo no centro do vaso sanguíneo e irregularidades no fundo. (b) Hemorragias e manchas algodoadas. (c) Exsudatos duros e diversos microaneurismas - pontos vermelhos. (d) Retina com diversos sinais de retinopatia diabética. **Fonte:** Fraz et al. (2012b).


Figura 2.7: Outros sinais oculares

(a) Hemorragia vítrea e neovascularização no disco óptico. (b) Edema macular. **Fonte:** Hendrick et al. (2015).

2.4 Doenças da retina

Existem mais de cem doenças retinianas conhecidas, grande parte leva à perda visual podendo ser parcial ou total, apenas algumas possuem tratamento. No relatório da WHO (2012), são destacadas as seguintes causas como sendo as responsáveis pelos casos de cegueira entre os anos de 2006 e 2011: catarata, glaucoma, degeneração macular relacionada a idade, retinopatia diabética, oncocercose, tracoma e erros refrativos não tratados. Ou seja, doenças da retina são responsáveis por pelo menos 21% dos casos de cegueira.

Figura 2.8: Causas de cegueira no mundo



Fonte: WHO (2012).

Os trabalhos tomados como referência no presente contexto e as bases de imagens obtidas abrangem essencialmente o glaucoma e a retinopatia diabética, com isso, é comum que surjam referências a sinais oculares dessas doenças ao longo do trabalho. No apêndice B apresentamos maiores informações sobre o glaucoma e a retinopatia diabética.

2.5 Considerações finais do capítulo

Este capítulo apresentou conceitos fundamentais para a compreensão do trabalho. Dentre os principais, deve se destacar a fisiologia do olho humano, os sinais oculares, doenças da retina e o exame de fundo de olho.

A apresentação destes conceitos não visa esgotar o assunto, mas sim, garantir que o leitor possa compreender as técnicas apresentadas nos capítulos subsequentes, bem como permitir a compreensão dos elementos presentes nas imagens utilizadas nos experimentos, uma vez que muitas delas possuem sinais de glaucoma e retinopatia diabética.

No próximo capítulo são abordados outros conceitos relevantes para o entendimento do trabalho, principalmente em relação às bases de dados utilizadas e o *roughness index*.

CAPÍTULO 3

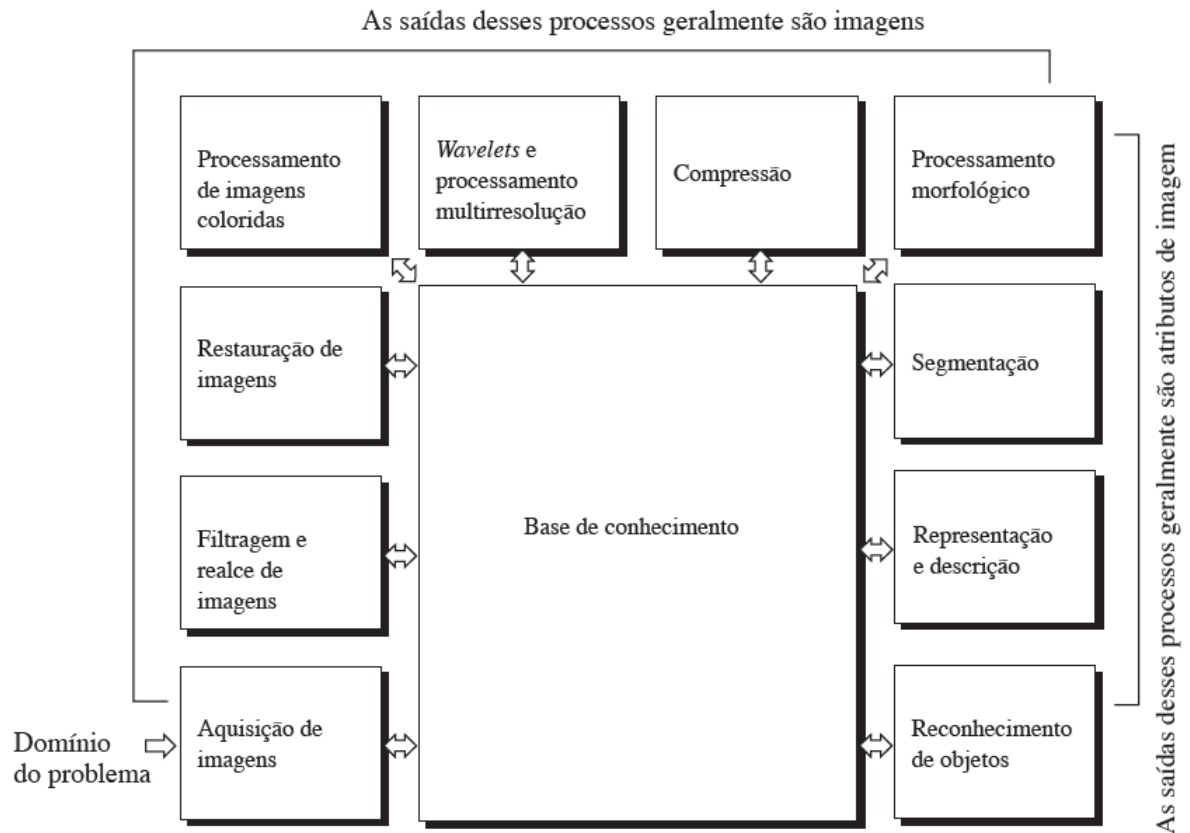
FUNDAMENTOS TEÓRICOS GERAIS

Este capítulo tem como propósito fornecer conceitos relevantes para o entendimento dos capítulos subsequentes sem que tais assuntos desviem a atenção do leitor. Inicialmente traçamos um paralelo entre o processamento e o reconhecimento de imagem para clarificar a importância da segmentação. Em seguida discutimos as principais métricas para avaliar a qualidade da segmentação e conceituamos transformada de Hough, histogramas, histograma e *roughness index*.

3.1 Processamento, análise, reconhecimento e segmentação de imagens

A Figura 3.1 sintetiza as diversas modalidades de técnicas para processamento de imagens: de maneira geral, qualquer técnica que promova melhorias, extraia informações, reduza a quantidade de informações, etc, pode ser designada de “processamento de imagens”. Por vezes, pode ser útil separar estas técnicas de acordo com o objetivo a ser alcançado, assim, a análise de imagens se volta para a extração de informações enquanto o reconhecimento, que é uma extensão da análise, busca classificar cenas ou objetos fazendo uso de técnicas de reconhecimento de padrões (GONZALEZ; WOODS, 2010; PEDRINI; SCHWARTZ, 2007).

A análise e o reconhecimento dificilmente são realizados em uma única etapa, normalmente dependem da aquisição, da melhoria da qualidade da imagem etc. Assim, o reconhecimento e a análise contam com um conjunto de passos abrangendo uma grande quantidade de técnicas de processamento de imagens. Tais passos fazem algo semelhante ao que é feito pelo sistema visual humano, sequencialmente, esses passos são os seguintes: aquisição, pré-processamento, segmentação, obtenção de características (representação e descrição), e final-

Figura 3.1: Passos fundamentais em processamento digital de imagens

Fonte: Gonzalez e Woods (2010).

mente o reconhecimento, todos esses passos estão representados na Figura 3.1 (GONZALEZ; WOODS, 2010).

Ao se realizar o reconhecimento de imagens não significa necessariamente que todas as etapas listadas acima serão percorridas, existem métodos analíticos e métodos baseados em transformadas, dentre outros, que conseguem realizar mais de uma dessas etapas em um único passo, como no método apresentado em Santos (2007).

Também é interessante notar a presença de uma base de conhecimentos que fornece direcionamento a todas as etapas. Tal base está intrinsecamente ligada ao domínio do problema e é o diferencial para que técnicas trabalhem até melhor que humanos em contextos restritos. Lembrando que contextos gerais são úteis apenas em visão computacional.

Portanto, a segmentação é uma das etapas no reconhecimento de imagens, sendo uma das mais importantes e delicadas: caso não seja bem realizada, o resultado final do reconhecimento é seriamente prejudicado. Por isso, a segmentação tornou-se uma área de estudo e vem sendo alvo de melhorias e aprimoramentos.

Diante do exposto, algumas considerações acerca deste trabalho devem ser feitas. Serão utilizadas técnicas de processamento de imagens afim de realizar a segmentação de imagens da retina, com isso espera-se viabilizar a implementação de sistemas de reconhecimento de patologias em imagens de fundo de olho.

3.2 Métricas para a avaliação da segmentação de Imagens


Em um problema de classificação de imagens, os objetos são separados em classes por um indivíduo¹, não necessariamente especialista e a classificação realizada pelo método é comparada ao resultado da classificação realizada inicialmente pelo indivíduo. Como a classificação manual é considerada “correta”, o objetivo do método é ser tão preciso quando ela, em consequência, a qualidade de um método é determinada com a contagem de objetos corretamente classificados, tendo por base a classificação manual. Neste contexto, quase sempre as classes são bem delimitadas e seus objetos são separados de forma simples.

Ao contrário da avaliação de métodos de classificação de imagens, a avaliação dos métodos de segmentação possui um caráter bastante subjetivo. Isso ocorre porque a saída do processo é uma imagem em que os objetos são separados por linhas ou colorações, e a validação do método é feita por comparação entre a imagem resultante e uma imagem segmentada “corretamente”. A imagem tida como referência para a verificação da qualidade da segmentação, designada por *ground truth*, é obtida pela segmentação manual realizada por especialistas. Considerando o contexto das imagens médicas, Kauppi et al. (2007) afirma que o *ground truth* contempla as informações sobre os achados médicos, por exemplo, quando o objetivo é encontrar os vasos sanguíneos, um especialista é consultado e deverá fazer marcação dos vasos nas imagens, gerando assim imagens binárias de *ground truth*, que contém apenas os vasos sanguíneos.

Algumas bases de imagens do fundo de olho fornecem o *ground truth* feito por mais de um especialista e por isso designa estas imagens de “padrão ouro” (BUDAI et al., 2013b). Outro item que pode ser encontrado nestas bases é a máscara para delimitar a região de interesse no fundo de olho, também chamada de *Field Of View* (FOV). A Figura 3.2 mostra a máscara relativa ao FOV na base apresentada por Staal et al. (2004): a parte preta não deve ser levada em consideração nas análises, principalmente no cálculo das métricas.

É importante salientar que essa abordagem de avaliação é válida e aceita em qualquer

¹Também pode ocorrer da aquisição ser realizada a partir de classes naturalmente distintas, por exemplo, espécies de animais ou plantas.

Figura 3.2: Máscara delimitando a FOV

Fonte: DRIVE, (STAAL et al., 2004).

contexto em que se realize a segmentação de imagens. Um exemplo é a base genérica BSDS500 que disponibiliza 500 imagens de diversos contextos e contornos e os resultados da segmentação por regiões feitos por 3 indivíduos (MARTIN et al., 2001).

Diante de uma imagem segmentada por um especialista e uma imagem segmentada por um método, diversas métricas podem ser definidas, sendo muito utilizadas a precisão, a taxa de verdadeiro positivos, a área sob a curva ROC etc. O cálculo de tais medidas é condicionado ao problema em questão, assim, um “verdadeiro positivo” significa que o objeto alvo foi classificado pelo método de acordo com o estabelecido pelo especialista. O objeto alvo pode ser qualquer elemento na imagem, no caso do fundo de olho, os possíveis alvos são o disco óptico, os vasos sanguíneos, exsudatos, microaneurismas etc. Presumindo que tal objeto tenha sido isolado na imagem segmentada, Purusharthi e Kurhade (2014) e Mittapalli e Kande (2016) definem os possíveis resultados desta comparação, que são apresentados na Tabela 3.1:

Tabela 3.1: Resultado da segmentação em comparação com a segmentação feita por um especialista.

Classificação	Descrição
TP (<i>True positive</i>) Verdadeiro positivo	pixels classificados pelo método e pelo especialista como pertencentes ao objeto.
TN (<i>True negative</i>) Verdadeiro negativo	pixels classificados pelo método e pelo especialista como não pertencentes ao objeto.
FP (<i>False positive</i>) Falso positivo	pixels classificados pelo método como pertencentes ao objeto e classificados pelo especialista como não pertencentes ao objeto.
FN (<i>False negative</i>) Falsos negativo	pixels classificados pelo método como não pertencentes ao objeto e classificados pelo especialista como pertencentes ao objeto.

A Figura 3.3 mostra os conjuntos de pixels resultantes de uma segmentação em compara-

- SN (*sensitivity*) - sensibilidade (Se), também designada por *recall*, é a proporção de verdadeiros positivos, sua intenção é quantificar a capacidade do método em detectar o alvo. Normalmente é utilizada em conjunto com a especificidade. Pode ser definida de duas maneiras distintas:

$$SN = \frac{\|TP\|}{\|TP + FN\|} \quad (3.3)$$

ou

$$SN = TPR \quad (3.4)$$

- SP (*specificity*) - especificidade, também designada por *precision*, é a proporção de verdadeiros negativos, ou seja, é a capacidade do método em encontrar os pixels não pertencentes ao alvo. Também pode ser definida de duas maneiras distintas:

$$SP = \frac{\|TN\|}{\|TN + FP\|} \quad (3.5)$$

ou

$$SP = 1 - FPR \quad (3.6)$$

- Acc (*Accuracy*) - precisão² é a taxa de acertos em relação ao total de pixels na área sendo investigada - FOV. As medidas de verdadeiro positivos e verdadeiro negativos (TP e TN) refletem o total de acertos na segmentação:

$$Acc = \frac{\|TP + TN\|}{\|FOV\|} \quad (3.7)$$

- ROC (*Receiver Operating Characteristic*) - é a curva que plota a fração de pixels do alvo corretamente classificados (TPR) versus a fração de pixels erroneamente classificados como pertencentes ao alvo (FPR);
- AUC (*Area Under the Curve*) - é a área sob a curva ROC;

²Embora a tradução para *precision* e *accuracy* possa ser a mesma, não definem a mesma medida, por isso, neste trabalho, optou-se pelo termo *specificity* em detrimento de *precision*. Grande parte da literatura consultada também adota esta terminologia. *Precision* e *recall* são mais utilizados em contextos gerais e recuperação de informação, (MARTIN et al., 2001) (SANTOS, 2007).

- F (F -score)³ - é a média harmônica entre a especificidade e sensibilidade⁴:

$$F = 2 \frac{SP \cdot SN}{SP + SN} \quad (3.8)$$

- DSM ($Dice$ Similarity Measure) - uma reformulação para a F -score:

$$DSM = \frac{2||TP||}{2||TP|| + ||FN|| + ||FP||} \quad (3.9)$$

- S ($Overlapping$ score) - é a taxa de sobreposição entre os pixels detectados pelo método e os pixels classificados pelo especialista:

$$S = \frac{||TP||}{||FP + TP + FN||} \quad (3.10)$$

Um bom classificador deve proporcionar alta sensibilidade e alta especificidade, o que implicará também em alta precisão. Sendo que a precisão (Acc) e a área sob a curva ROC são as principais medidas utilizadas na literatura, ambas unem informações sobre a habilidade do método em discernir gerando um único valor que facilita a comparação entre uma infinidade de algoritmos de forma rápida, direta e eficiente. O capítulo 6 ilustra o uso destas medidas - Tabelas 6.3 e 6.5.

3.3 Base de dados de Imagens

Muitos pesquisadores e institutos de pesquisa em oftalmologia disponibilizam bases de dados contendo imagens de retinografias digitais para facilitar as análises e/ou comparações de métodos. Cinco bases de dados públicas contendo imagens de fundo de olho foram coletadas e são utilizadas neste trabalho: DIARETDB1⁵, DRIVE⁶, HRF⁷, Messidor⁸ e STARE⁹.

DIARETDB1 (*DIAbetic RETinopathy DataBase*) é uma base de referência em detecção de retinopatia diabética que contém 89 imagens, das quais 84 apresentam NPDR intermediária caracterizadas pela presença de microaneurismas e as outras 5 imagens não apresentam qualquer

³Também chamada de F_1 -score ou F -measure.

⁴Normalmente é definida em termos de *precision* e *recall*, o que é apenas uma questão de terminologia

⁵Disponível em: <<http://www.it.lut.fi/project/imageret/diaretdb1/>>

⁶Disponível em: <<http://www.isi.uu.nl/Research/Databases/DRIVE/>>


⁷Disponível em: <<https://www5.cs.fau.de/research/data/fundus-images/>>

⁸Disponível em: <<http://www.adcis.net/en/Download-Third-Party/Messidor.html>>

⁹Disponível em: <<http://www.ces.clemson.edu/~ahoover/stare/>>

sinal de retinopatia diabética. As imagens foram capturadas com uma câmera para retinografia com 50°, com dimensões 1500×1152 , 8 bits por canal RGB. Esta base provê o *ground truth* realizado por 4 especialistas, em que foram marcados os microaneurismas, hemorragias, exsudatos duros e manchas algodonosas. Para cada marcação o especialista atribui um grau de confiança (KAUPPI et al., 2007). A Figura 3.4 mostra 3 imagens da base DIARETDB1 com seus respectivos *ground truths*: exsudatos duros, hemorragias, pontos vermelhos, manchas algodonosas (exsudatos moles).


Figura 3.4: Imagens da base DIARETDB1.



(a), (b) e (c) Imagens extraídas da base DIARETDB1. (d), (e) e (f) *Ground truth* dos exsudatos duros. (g), (h) e (i) *Ground truth* da hemorragias. (j), (k) e (l) *Ground truth* dos pontos vermelhos. (m), (n) e (o) *Ground truth* dos exsudatos moles. **Fonte:** base de imagens DIARETDB1, (KAUPPI et al., 2007).


A base mais referenciada na literatura é a DRIVE (*Digital Retinal Images for Vessel Extraction*), que conta com 40 imagens divididas em dois grupos, um de treinamento com 20 imagens e outro de teste, também com 20 imagens. São disponibilizados o *ground truth* dos dois grupos, no primeiro tem se apenas uma segmentação manual para cada imagem, já o grupo de teste conta com duas segmentações manuais, sendo que uma é considerada padrão ouro. As imagens foram capturadas por uma câmera Canon CR5 não midriática 3CCD com 45° e assim como nas outras bases citadas, é utilizado o modelo RGB com 8 bits em cada canal. O tamanho das imagens é 565×584 pixels, também são disponibilizadas máscaras para a FOV. A Figura 3.5 mostra exemplos de imagens coletadas da base DRIVE, (a) e (d) são imagens do conjunto *test*, (b) e (e) são seus respectivos *ground truth* 1, e (c) e (f) são seus respectivos *ground truth* 2 (STAAL et al., 2004).

Figura 3.5: Imagens da base DRIVE.



(a),(d) Imagens extraídas da base DRIVE. **(b)(c)** *Ground truth* 1. **(e)(f)** *Ground truth* 2. **Fonte:** base de imagens DRIVE, (STAAL et al., 2004).

A base HRF (*High Resolution Fundus*) conta com 45 imagens do fundo de olho em alta resolução, tamanho 3504×2336 , divididas em 3 grupos: 15 imagens de fundo de olho saudável, 15 com DR, e os outros 15 possuem glaucoma (BUDAI et al., 2013b). Para a obtenção das imagens foi utilizada uma câmera Canon CR-1, com um ângulo de 45°. Além das imagens em alta resolução, a base HRF também disponibiliza *ground truth* dos vasos sanguíneos e máscara para a FOV. A Figura 3.6 mostra exemplos de imagens da base HRF.

Figura 3.6: Imagens da base HRF.

(a) Olho saudável. (b) Olho com glaucoma. (c) Olho com retinopatia diabética. (d), (e) e (f) Respectivos *ground truths*. (g), (h) e (i) Respectivas FOVs. **Fonte:** base HRF (BUDAI et al., 2013b).

Messidor¹⁰ é uma base de dados contendo imagens de fundo de olho colhidas por meio de uma parceria de 3 departamentos de oftalmologia em pacientes que passaram por triagem de retinopatia diabética. As imagens foram capturadas com um retinógrafo digital *Topcon TRC NW6* não midriático com um ângulo de 45°. Ao total são 1200 imagens RGB com 8 bits por canal. Elas encontram-se separadas pelo departamento que realizou a aquisição, e os tamanhos são 1440×960 , 2240×1488 e 2304×1536 pixels. A FOV e o contorno do disco foram manualmente delimitados por especialistas do *Andalusian Health Service* (AQUINO et al., 2010), e estão disponíveis em <<http://www.uhu.es/retinopathy>>.

Segundo Decencièr et al. (2014), juntamente com a base Messidor, é fornecida a análise realizada por oftalmologistas em relação ao grau da retinopatia e o risco de edema macular. Os diferentes graus de retinopatia diabética são: PDR (*Proliferative Diabetic Retinopathy* - retinopatia diabética proliferativa) e NPDR (*No Proliferative Diabetic Retinopathy* - retinopatia

¹⁰Messidor é programa financiado pelo governo francês dentro do programa 2004 TECHNO-VISION. Pesquisadores e instituições se uniram sob a forma de um consórcio para coletar e analisar imagens de fundo de olho com o intuito de rastrear a retinopatia diabética. A base de dados gerada das coletas também foi chamada de messidor e vem sendo distribuída desde 2008.

diabética não proliferativa) - o Apêndice B traz maiores detalhes sobre os diferentes graus de retinopatia diabética. O diagnóstico da base Messidor é baseado nos critérios das Tabelas 3.2 e 3.3:

Tabela 3.2: Classificação dos níveis de DR na base Messidor

GRAU	QUANTIFICAÇÃO	CLASSIFICAÇÃO
0	$(MA = 0)AND(H = 0)$	Normal
1	$(0 < MA \leq 5)AND(H = 0)$	NPDR leve e moderada
2	$((5 < MA < 15)OR(0 < H < 5))AND(NV = 0)$	NPDR severa
3	$(MA \geq 15)OR(H \geq 5)OR(NV = 1)$	PDR

Fonte: Messidor, (DECENCIÈRE et al., 2014)

em que:


- MA - número de microaneurismas
- H - Número de hemorragias
- NV = 1 - presença de neovascularização
- NV = 0 - ausência de neovascularização

Já a classificação do risco de edema macular na Messidor leva em consideração apenas os exsudatos, Tabela 3.3.

Tabela 3.3: Classificação dos níveis de risco de edema macular na base Messidor

GRAU	QUANTIFICAÇÃO	CLASSIFICAÇÃO
0	Nenhum exsudato visível	Sem risco
1	menor distância entre a mácula e exsudatos duros > diâmetro de uma papila	risco médio
2	menor distância entre a mácula e exsudatos duros \leq diâmetro de uma papila	risco alto

A base STARE (*STructured Analysis of the REtina*) possui 400 imagens de fundo de olho coloridas, obtidas com câmera Topcon TRV-50 com um ângulo de 35°. Das 400 imagens, 20 são analisadas e segmentadas manualmente por 2 observadores, em que o primeiro é responsável pelo *ground truth* e o segundo se preocupa com vasos sanguíneos finos. As imagens foram coletadas por processo analógico e digitalizadas em um formato de 605×700 , RGB, com 8 bits em cada canal (HOOVER et al., 2000). A Figura 3.8 mostra exemplos de imagens da base STARE, na primeira linha (Figuras 3.8(a)–(c)) estão as imagens coloridas selecionadas da base, na segunda linha (Figuras 3.8(d)–(f)) as imagens correspondentes ao seus respectivos *ground*

Figura 3.7: Graus de retinopatia na base Messidor.

Fonte: base Messidor (DECENCIÈRE et al., 2014). Imagens editadas: recorte e alteração no brilho e contraste para enfatizar características.

truth e na terceira linha (Figuras 3.8(g)–(i)) a segmentação manual dos vasos sanguíneos com vistas a obter os vasos finos.


3.4 Transformada de Hough

Em análise de imagens uma das tarefas mais usuais é a identificação de formas geométricas, tais como círculos, retas e outras. Para resolver esta questão um método ou combinação deles podem ser utilizados observando-se a existência de características de invariância em relação a mudanças, afinal, é desejável que uma mesma solução possa ser utilizada quando se tem as mesmas formas maiores, ou rotacionadas, ou em posições distintas dentro da imagem. Assim, um bom método para reconhecimento de formas deve apresentar invariância a mudanças de escala, rotação e translação.

Diante de tais observações, Hough e Paul (1962) patentearam um método analítico de identificação de formas, que posteriormente foi generalizado por Ballard (1981). A ideia central do método é usar as equações fundamentais destas formas geométricas variando os parâmetros em função dos pontos presentes na imagem. O método generalizado de Ballard (1981) não faz uso de equações básicas da forma, mas sim de uma estrutura chamada *R-table* que trata o problema em função dos pontos de borda e seu ângulo em relação a um ponto no interior da forma (centróide).

Usualmente, quando o objetivo é detectar uma forma geométrica, opta-se pela parametrização e não pela forma generalizada. Por exemplo, a detecção de círculos é realizada levando em consideração a equação fundamental da circunferência:

$$(x_i - a)^2 + (y_i - b)^2 = r^2 \quad (3.11)$$

Figura 3.8: Imagens da base STARE.

(a)–(c) imagens extraídas da base STARE. (d)–(f) *ground truth*. (g)–(i) segmentação manual buscando vasos sanguíneos finos. **Fonte:** base de imagens STARE, (HOOVER et al., 2000).

onde (x_i, y_i) é um ponto qualquer do círculo, (a, b) é o centro e r o raio, o objetivo é simular valores de parâmetros para descobrir o centro do círculo. Ou seja, determina-se uma faixa de valores aceitáveis para o raio e para o centro de um possível círculo que passe pelo ponto de borda dado por (x_i, y_i) , caso a equação da circunferência seja obedecida, é contabilizado um acerto para tais valores. Esse procedimento é realizado para todos os pontos de borda, escolhendo-se ao final os valores de parâmetros que mais acumularam acertos. Também é comum o uso de coordenadas polares, em que se tem:

$$\begin{aligned} x &= a + r \cos \theta \\ y &= b + r \sin \theta \end{aligned} \quad (3.12)$$

Como no espaço de parâmetros tem-se os pontos e deseja-se saber o centro do círculo, a Equação 3.12 é reescrita como:

$$\begin{aligned} a &= x - r \cos \theta \\ b &= y - r \sin \theta \end{aligned} \quad (3.13)$$

3.5 Histograma

Em análise de imagens o histograma é uma ferramenta muito útil pois permite a obtenção de diversas medidas estatísticas como mínimo, máximo, variância etc. O histograma de uma imagem representa a distribuição discreta das probabilidades de intensidades e pode ser definido como uma função $h(r_k) = n_k$ em que r_k é o k -ésimo nível de intensidade e n_k é o número de pixels com a intensidade r_k (GONZALEZ; WOODS, 2010). No caso de imagens coloridas, é calculado um histograma para cada canal seguindo a Equação (MUSHRIF; RAY, 2008):

$$h_i(g) = \sum_{m=1}^M \sum_{n=1}^N \delta(I(m, n, i) - g), \text{ para } 0 \leq g \leq L - 1 \quad (3.14)$$

em que $i = \{R, G, B\}$, L é o nível de intensidade máxima em cada canal e $\delta(\cdot)$ é a função impulso de Dirac.

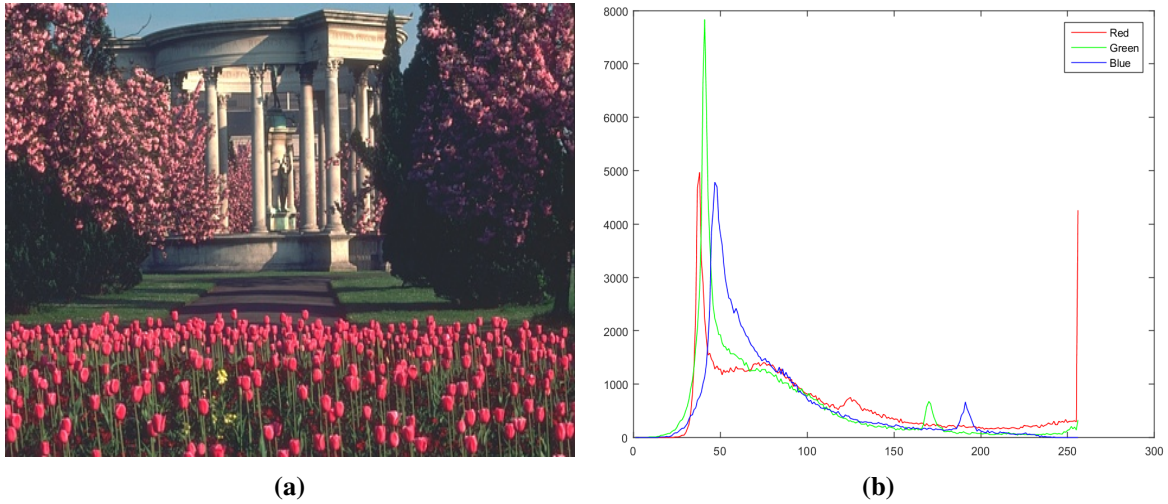
A Figura 3.9 mostra uma imagem colorida extraída da base Berkeley (MARTIN et al., 2001) e seu histograma RGB, sendo que o eixo horizontal representa os níveis de intensidade e o eixo vertical, o número de pixels em cada intensidade. Assim, picos no histograma podem ser traduzidos como as “cores” mais frequentes na imagem: em escala de cinza tem se na verdade o nível de brilho mais frequente, enquanto que em imagens coloridas, nas quais a cor é definida pela combinação dos canais RGB, a cor mais frequente é determinada por picos nos três canais, não necessariamente ocorrendo no mesmo nível de intensidade e podendo abranger um subconjunto de canais.

Partindo desta perspectiva, observa-se que a presença de picos isolados em um único canal diz que a imagem possui muita informação naquela cor ao passo que picos diversos não simultâneos são difíceis de serem analisados pois implicam em combinação das cores básicas. Já os picos simultâneos, ou seja, aqueles que ocorrem no mesmo nível de intensidade nos três canais, representam a cor cinza, variando do preto (intensidade 0) ao branco (intensidade máxima, 255 para imagens com 8 bits por canal). Por exemplo, o histograma da Figura 3.9 determina que a imagem que o gerou possui um bom contraste (o histograma está espalhado ao longo do eixo das intensidades), existe extensas áreas escuras (picos simultâneos em torno de 30), possui pouco verde e azul (pequenos picos entre 150 e 200 que parecem refletir combinação entre essas cores pois o formato dos picos são parecidos), possui grande intensidade para o vermelho (grande frequência de pixels na intensidade 255).

Duas desvantagens ocorrem na análise por meio de histogramas, a primeira está relacio-

nada a imagens coloridas que é a imprecisão da análise na presença de muitos picos, e a segunda se aplica a cores e escala de cinza, que é a ausência de informação espacial. Uma maneira de tornar estas informações mais precisas é por meio de histogramas 3D, e para obter uma associação de informações espaciais são utilizados histons no lugar de histogramas. Estas duas variações constituem parte importante da técnica empregada neste trabalho e serão discutidas adiante.

Figura 3.9: Imagem RGB e seu histograma



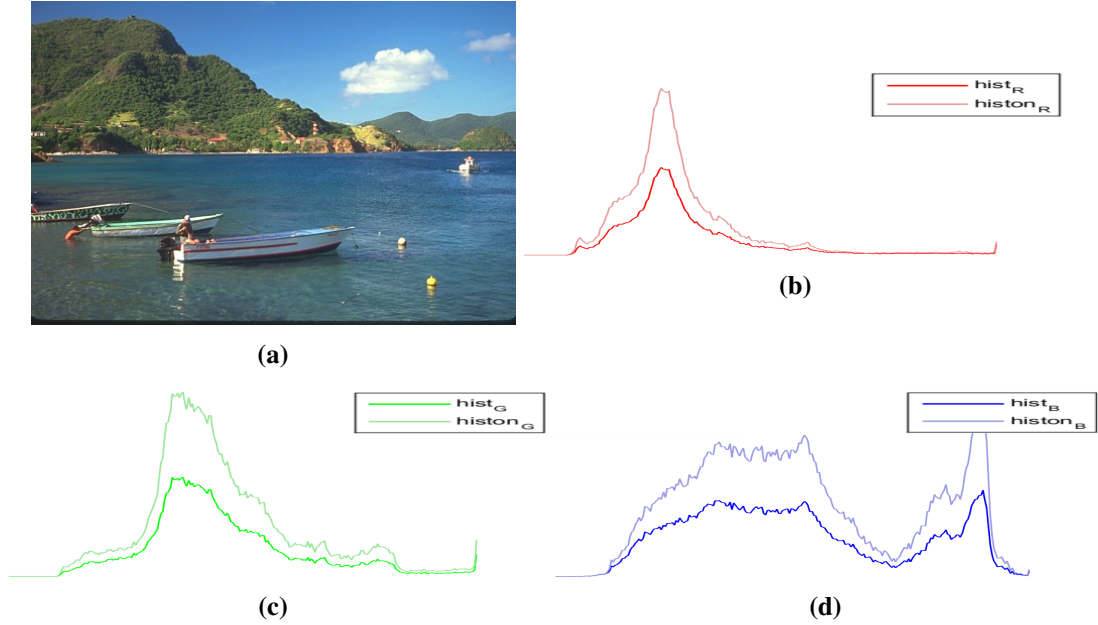
(a) Imagem colorida com grande intensidade no vermelho **Fonte:** Berkeley (MARTIN et al., 2001). (b) Histograma da imagem.

3.6 Histon

O histon, proposto por Mohabey e Ray (2000), é uma extensão do conceito de histograma em que se utiliza medidas de distância para criar uma versão expandida. Como a distância é tomada em relação aos pixels dentro de uma vizinhança, a maior vantagem do histon é que ele carrega consigo informações espaciais, ao contrário do histograma que é inteiramente probabilístico. O histon também é chamado de expansão pois quando plotado com o histograma pode ser visualizado como um contorno logo acima dele, Figura 3.10.

Diversos tipos de distâncias podem ser consideradas na obtenção do histon, sendo mais comum a distância euclidiana (MUSHRIF; RAY, 2010):

$$d(I(m,n), I(p,q)) = \sqrt{\sum_{k=(R,G,B)} (I(m,n,k) - I(p,q,k))^2} \quad (3.15)$$

Figura 3.10: Histon de imagem RGB

(a) Imagem colorida **Fonte:** Berkeley (MARTIN et al., 2001). (b) Histon e Histograma Red. (c) Histon e Histograma Green. (d) Histon e Histograma Blue.

em que I é uma imagem RGB de tamanho $M \times N$. Os índices (m, n) configuram a posição de um pixel qualquer no canal k e (p, q) é a posição de um pixel qualquer dentro da vizinhança em torno pixel (m, n) , também no canal k . Normalmente considera-se vizinhanças pequenas, tipicamente 3×3 ou 5×5 . Para obter a distância total deve ser feita a soma das distâncias para cada pixel da vizinhança:

$$d_T(m, n) = \sum_{p \in P} \sum_{q \in Q} d(I(m, n), I(p, q)) \quad (3.16)$$

O passo seguinte a obtenção da distância é determinar a esfera de cores similares, isso é feito por meio da aplicação de um critério de decisão com base no valor escolhido para a expansão:

$$X(m, n) = \begin{cases} 1 & d_T(m, n) < \text{expansão} \\ 0 & \text{caso contrário} \end{cases} \quad (3.17)$$

Assim, quando o valor da distância total de um pixel em relação a sua vizinhança d_T é menor que a expansão admite-se que o mesmo possui similaridade com seus vizinhos e portanto deve ser levado para o histon, que é definido como:

$$H_i(g) = \sum_{m=1}^M \sum_{n=1}^N (1 + X(m, n)) \delta(I(m, n, i) - g), \text{ para } 0 \leq g \leq L-1 \quad (3.18)$$

em que $i = \{R, G, B\}$, L é o nível de intensidade máxima em cada canal e $\delta(\cdot)$ é a função impulso de Dirac. Considerando que o histograma $h_i(g)$ é o cálculo da frequência de cada pixel, e que o histograma $H_i(g)$ deriva do histograma, a Equação 3.18 pode ser interpretada da seguinte forma: caso o pixel seja similar aos seus vizinhos, ele será contabilizado duas vezes, do contrário, segue o cálculo padrão do histograma contabilizando ele apenas uma vez. Assim, o histograma tem picos maiores em níveis de intensidade que correspondem a áreas constantes (interior de objetos da cena) e se aproxima do histograma em níveis de intensidade que correspondem a transição entre objetos, pois neste caso a distância entre os vizinhos é alta.

A expansão determina a distância máxima tolerada para que uma vizinhança seja considerada área constante e pode ser entendida como o raio da esfera de cores RGB similares que se admite na resolução do problema de segmentação. Mushrif e Ray (2008) sugerem o uso do valor 100, mas verifica-se dependência em relação ao tipo de imagem considerada, este valor pode diminuir em imagens com baixo contraste ou aumentar, caso contrário.

3.7 Teoria dos conjuntos aproximativos

Rough Set Theory, ou Teoria de Conjuntos Aproximativos, é uma ferramenta matemática com aplicabilidade em diversas áreas do conhecimento humano: aprendizado de máquina, aquisição de conhecimento, reconhecimento de padrões etc (VLACHOS; SERGIADIS, 2007). Foi proposta por Pawlak (1982) e trata a incerteza de uma base de conhecimento utilizando aproximações.

Rough sets surgem da incerteza na hora de classificar elementos em um conjunto, Pal e Peters (2010) dizem que “um conjunto é considerado *rough* se a fronteira entre as aproximações inferior e superior é não vazia”. Na prática, toda base de informações está relacionada a um tipo de incerteza, isso pode ser decorrente de fatos imperfeitos ou de conhecimento impreciso. Em consequência disso chega-se a um importante conceito, a indiscernibilidade, que é definida como uma relação de equivalência dentro de um conjunto de elementos no qual diferentes objetos podem possuir o mesmo valor para um determinado conjunto de atributos. Ao perceber esta característica, Pawlak (1991) definiu um sistema de informação¹¹ permitindo um tratamento formal e sistemático da indiscernibilidade por meio da teoria de conjuntos, surgindo então os *rough sets*.

¹¹Inicialmente, Pawlak utilizava um espaço de aproximação definido por um par $A = (U, R)$ em que U é o conjunto universo e R uma relação de indiscernibilidade (PAWLAK, 1982). Posteriormente este conceito foi expandido para sistema de informação, conforme a teoria da informação.

Pawlak (1991) assume que todo objeto de um universo (finito) está associado a uma quantidade de atributos (finita), e estes atributos possuem um conjunto de valores (finitos) configurando-se uma tupla $S = \langle U, A, V, f \rangle$, em que U é o conjunto universo, A o conjunto de atributos, V o conjunto de valores dos atributos e f é a função que define o sistema: $f : U \times A \rightarrow V$, além disso, cada atributo possui seu próprio conjunto de valores em V , assim, para todo $a \in A$, $a : U \rightarrow V_a$, sendo V_a o conjunto de valores para o atributo a . Há também uma outra maneira de tratar estes conjuntos que é na forma tabelas de informação, organizadas no formato (dados, atributos) (PAWLAK et al., 1995). Conforme Mushrif e Ray (2008) a indiscernibilidade pode ser definida a partir de um subconjunto de atributos B como:

$$IND(B) = \{(x, y) \in U \times U : \text{para cada } a \in B, a(x) = a(y)\} \quad (3.19)$$

Quando um subconjunto de elementos de U possui os mesmos valores para os atributos de B é dito que estes elementos satisfazem a relação $IND(B)$, Equação 3.19, e portanto, são indiscerníveis em relação a B configurando uma classe de equivalência, enquanto que B é um conhecimento na base de conhecimentos K de um sistema de informação. Considerando que cada atributo b em B está associado a um conjunto de valores V_b , mais de uma classe de equivalência pode ser obtida da relação de indiscernibilidade $IND(B)$, assim a união de todas as classes de equivalência em U com relação ao conhecimento B é denotada por $U/IND(B)$ e são designadas de categoria básica, ou conceito, do conhecimento B (PAWLAK, 1991; MUSHRIF; RAY, 2008). Com isso, é possível definir as aproximações inferior e superior do conceito X em relação ao conhecimento B , tal que $X \subseteq U$:

$$\underline{RX} = \cup\{Y \in U/IND(B) : Y \subseteq X\} \quad (3.20)$$


$$\overline{RX} = \cup\{Y \in U/IND(B) : Y \cap X \neq \emptyset\} \quad (3.21)$$

Os conjuntos aproximados inferior, Equação 3.20 e superior, Equação 3.21, podem ser vistos respectivamente, como os elementos que estão com certeza na categoria básica do conhecimento B , ou seja X , e elementos que possivelmente estão na categoria básica do conhecimento B . Os elementos que estão em \overline{RX} e não estão em \underline{RX} caracterizam a região fronteira, que é definida como:

$$BN_R(X) = \overline{R}X - \underline{R}X \quad (3.22)$$

A Figura 3.11 esboça graficamente estas aproximações. O contorno em vermelho denota o conceito X , enquanto que em amarelo tem se aproximação inferior, *lower*, já o contorno em preto com linhas largas denota a aproximação superior, *upper*, do conceito X , que é o conjunto de todos os elementos de U que podem (ou não) serem classificados como pertencentes a X por meio do conhecimento B .

Figura 3.11: Rough Set



Fonte: nicolejuliaphotography¹².

A região da fronteira também conhecida como *B-borderline* traz informações sobre a inexactidão do conjunto X em relação ao conhecimento B : quanto maior a quantidade de elementos sobre a fronteira maior a inexactidão. Idealmente, para se ter uma boa classificação dos objetos em um conjunto, é esperado que não existam muitos atributos para os quais haja indiscernibilidade, e quando houver, preferencialmente, que os elementos possam ser colocados na aproximação *lower*. Assim, uma simples medida de precisão em relação às aproximações é definida como:

$$\alpha_B(X) = \frac{\|\underline{R}X\|}{\|\overline{R}X\|} \quad (3.23)$$

onde $\|\cdot\|$ denota a quantidade de elementos do conjunto, sendo que $\|\overline{R}X\| \neq 0$, e $0 \leq \alpha_B(X) \leq 1$, afinal a aproximação *upper* contém a aproximação *lower* e portanto possui cardinalidade maior ou igual à aproximação *lower*. Quando $\|\underline{R}X\| = \|\overline{R}X\|$ é dito que X é mensurável em B (PAWLAK, 1982).

¹²Disponível em: <<http://www.nicolejuliaphotography.com/thyroid-diagnosis-rough-sets/>> acessado em jun. 2016.

A medida de precisão $\alpha_B(X)$ diz o quanto o conhecimento B é completo em relação ao conjunto X . Embora esta medida seja de grande relevância, a medida mais importante no contexto deste trabalho é o *roughness index* de X , que é o grau de inexatidão do conjunto X , dado por (MUSHRIF; RAY, 2008):

$$\rho_B(X) = 1 - \alpha_B(X) \quad (3.24)$$

em que $0 \leq \rho_B(X) \leq 1$. Quando $\rho_B(X) = 0$ observa-se que $\|\underline{RX}\| = \|\overline{RX}\|$ e portanto, não existe nenhum elemento na região de fronteira caracterizando que X é B -definível. Por outro lado, se $\rho_B(X) \neq 0$, existe elementos na região de fronteira, logo, X é B -indefinível (MUSHRIF; RAY, 2008).

Assim, um passo importante no uso de *rough sets* é determinar as aproximações *lower* e *upper* garantindo que o problema seja bem delimitado, o que faz com que as soluções sejam específicas às situações. Em segmentação de imagens é comum utilizar o histograma e o histon como aproximações inferior e superior respectivamente.

3.7.1 Atanassov's Intuitionistic Fuzzy Set (A-IFS)

A primeira pessoa a inferir sobre o uso de lógica fuzzy em processamento de imagens foi Prewitt (1970), que destacou aspectos da pertinência dos pixels na imagem, posteriormente Pawlak (1982) apresentou uma aproximação para processamento de imagens e reconhecimento de padrões utilizando fuzzy, embora este tenha sido um trabalho bastante relevante, possui um problema na formulação apresentada que é a atribuição do grau de pertinência de um pixel a um determinado conjunto fuzzy, considerada imprecisa. Assim, os trabalhos seguintes dentro deste assunto buscavam, principalmente, a resolução deste problema. Um dos trabalhos proposto neste sentido é apresentado Vlachos e Sergiadis (2007) que utiliza Atanassov's *Intuitionistic Fuzzy Sets*, que é uma generalização de conjuntos fuzzy, melhorando a confiabilidade no grau de pertinência por meio de medidas de discriminação da informação, entropia cruzada e entropia não probabilística De Luca-Termini.

Levando em consideração a efetividade desta teoria em imagens médicas e segmentação de imagens, Mushrif e Ray (2009) introduzem uma nova aproximação *upper* para a obtenção do *roughness index* na qual empregam Atanassov's *Intuitionistic Fuzzy Set* (A-IFS) na geração do histon, concebendo assim o A-IFS histon que possui o diferencial de usar a hesitância e

pertinência para decidir se um pixel está ligado a seus vizinhos em uma região homogênea ou se está em uma região de fronteira. Como foi dito anteriormente, o histon utiliza uma função como critério para decidir se o pixel está dentro da expansão ou não, é exatamente nesta função que o A-IFS é inserido.

Para se compreender este conceito é necessário definir a representação A-IFS da imagem que segundo Mushrif e Ray (2009) é dada por:

$$I = \{\langle g_{ij}, \mu_I(g_{ij}), \nu_I(g_{ij}) \rangle | i = 1, \dots, M, j = 1, \dots, N\} \quad (3.25)$$

em que g_{ij} é o (i, j) -ésimo pixel da imagem, $\mu_I(g_{ij})$ é o grau de pertinência e $\nu_I(g_{ij})$ é o grau de não pertinência deste pixel. Sendo que o grau de pertinência é dado pela normalização no nível de intensidade:

$$\mu_I(g_{ij}) = \frac{g_{ij}}{L-1} \text{ para } g \in \{0, \dots, L-1\} \quad (3.26)$$

O grau de não pertinência é dado pelo grau de pertinência e também pela hesitância. Em segmentação de imagens a hesitância constitui um importante conceito pois sempre que ocorre uma projeção para 2D, reamostragem, discretização, sombras de maneira geral, ocorre a hesitância em classificar os pixels como sendo de um objeto (ou região). De maneira geral, quando um pixel está em uma região homogênea a hesitância é menor, do contrário, quando um pixel está na fronteira de um objeto ou região a hesitância aumenta pois a variação das intensidades neste local é bem maior. O primeiro passo para obter a hesitância é determinar a média de intensidade na região, pois assim, tem-se uma medida que informa a relação entre o pixel e seus vizinhos, isso é feito por meio do filtro da média sobre o grau de pertinência:

$$\mu_I^a(g_{ij}) = \sum_{k=-1}^1 \sum_{l=-1}^1 \mu_I(g_{(i+k)(j+l)}) h(i+k, j+l) \quad (3.27)$$

em que h é a máscara do filtro da média, $1 \leq i \leq M$ e $1 \leq j \leq N$. A partir de $\mu_I^a(g_{ij})$ define-se então o grau de hesitância:

$$\pi_I(g_{ij}) = (1 - \mu_I(g_{ij})) \frac{|\mu_I(g_{ij}) - \mu_I^a(g_{ij})|}{\max_{i=1}^M \left(\max_{j=1}^N |\mu_I(g_{ij}) - \mu_I^a(g_{ij})| \right)} \quad (3.28)$$

Com o grau de pertinência e a hesitância define-se o grau de não pertinência:

$$\nu_I(g_{ij}) = 1 - \mu_I(g_{ij}) - \pi_I(g_{ij}) \quad (3.29)$$

devido ao termo $(1 - \mu_I(g_{ij}))$ na Equação 3.28 garante-se que o grau de não pertinência esteja no intervalo $[0, 1]$. Por fim, redefine-se o conceito de histon, Equação 3.18, gerando-se o A-IFS histon:

$$F_i(g) = \sum_{m=1}^M \sum_{n=1}^N (1 + \tilde{X}(m, n)) \delta(I(m, n, i) - g), \text{ para } 0 \leq g \leq L-1 \quad (3.30)$$

em que $i \in \{R, G, B\}$ e $\lambda(m, n)$ é uma função de pertinência gaussiana dada por:

$$\tilde{X}(m, n) = \exp \left(-0.5 \left(\frac{d_T(m, n)}{\sigma} \right)^2 \right) \quad (3.31)$$

sendo que σ é o desvio padrão da matriz d_T . O cálculo de d_T segue a Equação 3.16, porém com a distância d em relação a vizinhança, Equação 3.15, alterada para contemplar o grau de pertinência, o grau de não pertinência e a hesitância:

$$\begin{aligned} d(I(m, n), I(p, q)) &= \left(\frac{1}{6} \sum_{i \in \{R, G, B\}} \left[(\mu^i(I(m, n)) - \mu^i(I(p, q)))^2 \right. \right. \\ &\quad + (v^i(I(m, n)) - v^i(I(p, q)))^2 \\ &\quad \left. \left. + (\pi^i(I(m, n)) - \pi^i(I(p, q)))^2 \right] \right)^{0.5} \end{aligned} \quad (3.32)$$

O histograma fuzzy é definido conforme:

$$f_i(g) = \{(i, j) | \mu_I(g_{ij}); i = 1, \dots, M, j = 1, \dots, N\} \quad (3.33)$$

Com isso, define-se o *roughness index*:

$$\rho_i(g) = 1 - \frac{\|f_i(g)\|}{\|F_i(g)\|} \quad (3.34)$$

para $0 \leq g \leq L-1$ e $i = \{R, G, B\}$.

Com a introdução da representação A-IFS deve ocorrer uma melhor decisão sobre a pertinência do pixel em relação a um objeto (ou região) produzindo uma aproximação superior, histon, mais efetivo.

3.8 Segmentação por *Roughness Index*

A segmentação por *roughness index*¹³ é semelhante a segmentação baseada em histograma. Neste tipo de segmentação vales constituem a fronteira entre os objetos, pois representam pixels menos frequentes, enquanto que picos constituem regiões ou objetos. Embora a ideia seja simples e coesa, na prática seu funcionamento é bastante restrito, na maioria dos casos a intensidade é um parâmetro fraco para separar tais elementos, objetos pequenos podem ser subestimados e os níveis de intensidades determinados como separadores podem estar espalhados na imagem resultando em uma segmentação ineficiente.

Mesmo com estas desvantagens, a segmentação baseada em histogramas também possui aspectos positivos, que são a rapidez, a auto-adaptação e simplicidade em implementar. Assim, é possível obter um excelente método de segmentação agregando características espaciais a segmentação (limiarização) por histogramas, para isso foi proposta a segmentação por meio do *roughness index* (MUSHRIF; RAY, 2008).

O bom funcionamento do *roughness index* é garantido por uma propriedade de sua construção: áreas de transição são transformadas em vales, mesmo na presença de pequenos segmentos. Isso ocorre, porque quanto maior o valor do histon em relação ao histograma, maior o valor do *roughness index*, que se torna próximo a 1. Locais de máximo no *roughness index* podem ser traduzidos como áreas homogêneas na imagem (baixa frequência). Por outro lado, áreas de transição de níveis de intensidade na imagem (alta frequência) produzem baixa similaridade o que faz com que o critério de decisão usado na geração do histon não seja satisfeito pois a distância na vizinhança é superior a expansão, neste caso o histograma e o histon se aproximam tornando o *roughness index* pequeno e ocasionando vales que podem ser interpretados como *thresholds*.

A determinação do histograma, do histon e do *roughness index* foram dadas anteriormente, já a determinação dos vales significantes, que serão os *thresholds* da segmentação, é determinada por Mushrif e Ray (2008), Algoritmo 1. Dada a média do *roughness index*, qualquer nível de intensidade que possui valor 20% acima de tal média e que esteja a uma distância de pelo menos 10 do nível de intensidade que contém outro pico é considerado um pico. Depois que todos os picos são determinados pelo algoritmo, encontra-se os vales: um vale é um valor mínimo entre dois picos, sendo que cada vale é um *threshold* para a limirização *multithreshold*.

Ao considerar cada vale do *roughness index* como um *threshold* pode ocorrer a super-

¹³Também chamado de *rough measure*

Algoritmo 1: Seleciona *thresholds*

```

input : Roughness Index RI
output : Thresholds correspondentes aos vales significantes do RI

1 begin
    /* Inicialmente encontra se os picos mais significativos */
2    $M \leftarrow \text{Media}(\text{RI})$ ;
3    $j \leftarrow 1$ ;
4   foreach posição  $i$  em RI do
5       if  $\text{RI}(i) > 1.2M \ \& \ (i - \text{picos}(j)) > 10$  then
6            $\text{picos}(j) \leftarrow i$ ;
7            $j \leftarrow j + 1$ ;
8       end
9   end
    /* Em seguida encontra se os vales: um vale é o valor mínimo
       entre dois picos */
10   $j \leftarrow 1$ ;
11  foreach posição  $i$  em picos do
12       $\text{vales}(j) \leftarrow \text{PosicaoMinimoNoIntervalo}(\text{RI}, \text{picos}(i), \text{picos}(i + 1))$ ;
13       $j \leftarrow j + 1$ ;
14  end
15 end

```

segmentação da imagem, o que leva a necessidade de unir pequenas regiões a outras maiores, ou ainda, unir *thresholds* que estejam muito próximos, esta operação é chamada de *merging* de regiões. Conforme Cheng et al. (2002) uma maneira de unir regiões, ou *clusters*, é por meio da definição de um tamanho mínimo esperado, e de uma distância mínima entre os *thresholds*. O algoritmo 2 apresenta o *merging*: cada *cluster* é definido por dois *thresholds* e deve ter tamanho mínimo de 10% do tamanho da imagem, inicialmente, cada *cluster* é inspecionado em relação ao tamanho mínimo; se o tamanho do *cluster* estiver abaixo deste tamanho, ele deverá ser unido ao próximo *cluster*. Na etapa final do algoritmo, a distância entre os *thresholds* é verificada, se dois *clusters* estiverem a uma distância inferior a 20, eles deverão ser unidos.

O algoritmo de segmentação proposto por Mushrif e Ray (2008) é representado no fluxograma da Figura 3.12: obtém-se o histograma e o histon, calcula-se o *roughness index*, determina-se os vales mais significantes, que são usados para limiarizar a imagem, e por último realiza-se o *merging* para evitar supersegmentação.

Assim, segmentação por meio do *roughness index* é uma segmentação baseada em histograma na qual se utiliza aproximações e informação espacial, favorecendo o seu uso até mesmo em imagens com baixo contraste (MUSHRIF; RAY, 2008).

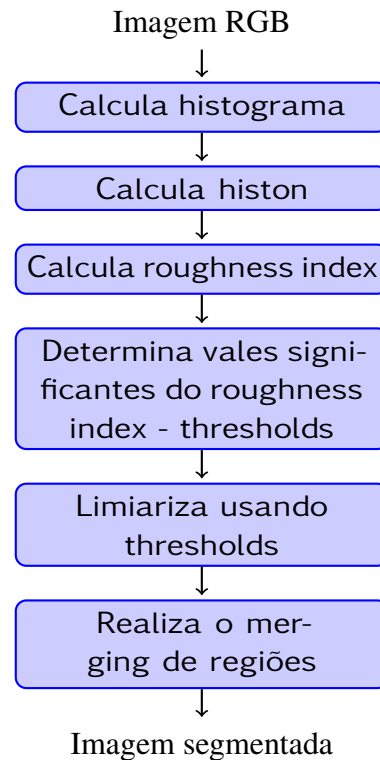
Algoritmo 2: *Merging de regiões*

input : *Thresholds ths* e imagem *I*
output : *Novos thresholds ths*

```

1 begin
  /* Inicialmente busca-se os menores clusters */
2  menorTc  $\leftarrow$  0;
3  minimoTc  $\leftarrow$  0.1Tamanho (I); /* tam. do cluster, Cheng (2002) */
4  minimaDistancia  $\leftarrow$  20; /* dist entre clusters, Cheng (2002) */
5  menorDistancia  $\leftarrow$  0;
6  while menorTc < minimoTc do
7    foreach posição i em ths do
8      tc  $\leftarrow$  TamanhoCluster (I, ths(i), ths(i + 1));
9      if tc < minimoTc then
10       | ths  $\leftarrow$  MergeCluster (ths, ths(i), ths(i + 1));
11       end
12     end
13     menorTc  $\leftarrow$  TamanhoMenorCluster (I, ths);
14 end
  /* Em seguida ajusta se as distâncias entre os clusters */
15 while menorDistancia < minimaDistancia do
16   foreach posição i em ths do
17     dist  $\leftarrow$  (ths(i + 1) - ths(i));
18     if dist < minimaDistancia then
19       | ths  $\leftarrow$  MergeCluster (ths, ths(i), ths(i + 1));
20       end
21     end
22     menorDistancia  $\leftarrow$  TamanhoMenorDistancia (ths);
23 end
24 end

```

Figura 3.12: Algoritmo de segmentação por *roughness index*

Fonte: Adaptado de (MUSHRIF; RAY, 2008)

3.9 Considerações finais do capítulo

Este capítulo discutiu características de algumas bases de imagens contendo fundo de olho e apresentou conceitos fundamentais em processamento, segmentação de imagens e *rough sets*. Inicialmente foi traçado um paralelo entre processamento, análise e reconhecimento de imagens para que o leitor possa compreender a natureza deste trabalho e a importância da segmentação. Sem uma boa segmentação, o reconhecimento de imagens, e por conseguinte o reconhecimento de patologias em imagens de fundo de olho, é inviabilizado.

Em segmentação foram destacadas as métricas utilizadas para validar a qualidade dos métodos. Deve ser observado o caráter subjetivo de tais métricas, uma vez que são obtidas a partir da segmentação manual realizada por especialistas. Apesar da subjetividade, esse padrão é amplamente aceito, e por isso, bases relevantes são concebidas de maneira criteriosa e disponibilizam tais informações, segundo Kauppi et al. (2013), isso favorece a comparação dos algoritmos possibilitando a criação de métodos cada vez mais robustos, facilitando também a transferência de tecnologia para a prática clínica.

É importante salientar que o ponto principal tratado neste capítulo tange aos *rough sets* e *roughness index*, em que foram definidas sua forma de obtenção, variações do método e particularidades. Também foram tratados aspectos importantes relativos a transformada de Hough. No próximo capítulo serão abordados trabalhos que condizem com estado da arte em segmentação de imagens de fundo de olho e trabalhos correlatos.

Este capítulo discute os principais trabalhos em segmentação de imagens do fundo de olho. Nas próximas seções são discutidos trabalhos relevantes em localização e segmentação do disco óptico, e em segmentação dos vasos sanguíneos.

4.1 Segmentação do disco óptico

A identificação do disco óptico é de grande importância para qualquer método de análise automática em imagens de fundo do olho, ela é necessária na localização de estruturas como a fóvea e os vasos sanguíneos, e também na diferenciação entre o disco óptico e sinais patológicos, como os exsudatos. Além disso, o disco óptico é o principal objeto de estudo em patologias como o glaucoma.

O disco óptico possui um bom contraste em relação aos outros elementos da retina, teoricamente isso o torna um elemento de fácil segmentação favorecendo o uso de limiares. No entanto, a fisiologia do mesmo não é tão simples, o disco óptico sempre se apresenta encoberto pelos vasos centrais da retina, podem haver exsudatos próximos e a coloração no lado nasal é mais escura¹ do que no lado temporal. Há também uma condição chamada *peripapillary atrophy* (PPA) que torna a borda do disco irregular dificultando sua detecção, a maioria dos métodos apresenta problemas na presença desta anomalia.

Diversas metodologias são aplicadas na detecção do disco óptico, algumas se preocupam em apenas localizar este elemento, enquanto outras chegam a particioná-lo, geralmente com o objetivo de detectar glaucoma. Algo comum a muitos trabalhos é que a segmentação desta

¹ Isso ocorre em função da maior concentração de vasos capilares e feixe de fibras papilomaculares mais grossas neste local (DORION, 2002).

estrutura é feita em duas etapas, a primeira é uma aproximação, apenas localiza o disco óptico, e a segunda é o refinamento, que delimita com precisão suas fronteiras. Informações como a forma, o tamanho e a intensidade são conhecidas e discutidas em oftalmologia e fornecem importantes indicativos para os métodos de segmentação.

4.1.1 Localização do disco óptico

Métodos para localizar o disco devem ser rápidos e eficientes, pois quase sempre são uma pré-etapa de algoritmos mais complexos de segmentação, é o caso dos algoritmos de *tracking* para segmentação dos vasos sanguíneos: iniciam no disco e encontram todos os vasos (MOOKIAH et al., 2013c).

Alguns métodos para localização do disco óptico podem ser bastante simples como é o caso do método apresentado em Sinthanayothin et al. (1999) que considera o ponto com maior variância como sendo o centro do disco óptico e então delimita uma área que corresponde ao tamanho do disco em torno do ponto selecionado, a taxa de especificidade obtida é de 99.1%. Pinão (2011) considera informações conhecidas sobre posicionamento e dimensões do disco óptico e aplica o filtro Sobel para realizar a localização.

Uma técnica amplamente utilizada para resolver esta questão é *Principal Components Analysis* (PCA)². Mittapalli e Kande (2016) usam essa técnica para reduzir a variância e minimizar o erro ocasionado pela redução de dimensionalidade. Além de PCA, a transformada de Hough possui grande importância neste contexto, em muitos trabalhos a localização do disco óptico é feita por transformada de Hough circular que obtém formas geométricas a partir da análise de contornos gerados por filtros (Canny, Robert, Sobel etc). Mary et al. (2015) e Chrástek et al. (2005) adotam esta abordagem.

Yang et al. (2011) utiliza um método baseado em *matched filtering* com ajuste de contraste, operações morfológicas e informação tangente para localizar o disco óptico. O *matched filtering* é usado para reduzir a influência dos vasos sanguíneos, enquanto que o ajuste de contraste e operações morfológicas amenizam problemas com ruído e iluminação, já a informação tangente é usada para localizar o disco óptico. Sua taxa de acerto é de 91.3 % na base STARE. Budai et al. (2012) também inicia seu método eliminando a influência dos vasos sanguíneos com suavização gaussiana, após esta etapa são gerados dois mapas de probabilidades, sendo um para o brilho da imagem (obtido do modelo de cores HSV) e outro para a imagem com os vasos segmentados, a

²PCA também é conhecida como transformada Karhunen-Loève.

posição do disco óptico é obtida ao multiplicar os dois mapas.

Cheng et al. (2013) utiliza superpixels para realizar a localização inicial do disco óptico: medidas estatísticas são usadas para classificar o superpixel em “disco” ou “não disco” usando *bootstrapping*. Sua abordagem traz mais rapidez quando se tem imagens em alta resolução. Fan et al. (2015) também fazem uso de superpixel, inicialmente uma sub-imagem é gerada com o auxílio de mapa de saliência, feito isso, os superpixels são gerados com um algoritmo *Simple Linear Iterative Clustering* (SLIC) e classificados com AdaBoost.

Harangi e Hajdu (2015) apresenta uma combinação de vários algoritmos resultando em um *framework* para localizar o disco óptico. São obtidos diversos candidatos que são ordenados pelo grau de confiança no algoritmo, por fim, aplica-se grafos e probabilidade no processo de determinação do disco.

Em uma alternativa de método supervisionado para localização do disco óptico, Ramakanth e Babu (2014) estendem o método chamado *Approximate Nearest Neighbour Field maps* para análise em imagens médicas, este método realiza a busca de características semelhantes às características extraídas de uma imagem analisada a priori, são utilizados *patches* e *likelihood* na comparação ocasionando em uma taxa de acerto de 99%. Os testes são realizados em um conjunto de mais de 1500 imagens retiradas de diversas bases conhecidas.

Métodos de aprendizado de máquina também são utilizados para resolver a localização do disco óptico, Niemeijer et al. (2009) modela a localização da fóvea e do disco óptico como um problema de regressão e utiliza *k-Nearest Neighbors regressor* (kNN regressor) para prever a distância entre os pixels e o objeto de interesse. São consideradas características locais e informações da vasculatura para a escolha do local que corresponde ao disco. Como resultado, Niemeijer et al. obtém 99,4% de acerto na delimitação do disco óptico em um conjunto de 500 imagens escolhidas de triagem de retinopatia diabética.

Os métodos de localização do disco óptico apenas informam o local na imagem de fundo de olho em que o disco se encontra, geralmente apenas marcando um ponto, alguns métodos podem informar o centro do disco. Conforme Niemeijer et al. (2009) a literatura sobre o assunto informa que a localização é considerada correta se um ponto dentro do disco é marcado, calcula-se dessa forma a taxa de acerto, por vezes também designada por *accuracy*. Assim, se o objetivo for uma segmentação mais robusta outros métodos devem ser utilizados, conforme é discutido na seção a seguir.

4.1.2 Delimitação do disco óptico

Os principais métodos para se obter a efetiva segmentação do disco óptico são baseados em modelos deformáveis, classificação supervisionada de pixels, conjuntos aproximativos e transformada de Hough circular. Sekhar et al. (2008) e Soman e Ravi (2014) utilizam a transformada de Hough circular para delimitar o disco óptico. Como essa transformada se baseia em equações paramétricas, o problema de PPA não é bem resolvido, apenas os discos ópticos com bordas regulares geram bons resultados, assim, ajustes e métodos adicionais devem ser aplicados para resolver esta questão, por exemplo, Soman e Ravi (2014) utilizam fatiamento do plano de bits para obter uma aproximação mais robusta.

Considerando trabalhos que fazem uso de modelos deformáveis, Mittapalli e Kande (2016) apresentam um trabalho bastante relevante, em que *active contour model* é usado para obter uma segmentação precisa do disco óptico. Inicialmente é aplicado *matched filter* com *kernel* Gaussiano-Hermitiano para segmentar os vasos sanguíneos e assim realizar o *inpainting* dos vasos no disco óptico, que é obtido a priori por meio de PCA. Para garantir precisão na delimitação do OD este trabalho propõe um novo modelo de contorno ativo baseado em região implícita no qual informações de vários canais são adicionadas ao local de interesse, garantindo assim uma segmentação mais robusta. As informações utilizadas incluem intensidade, cor e textura. Além de Mittapalli e Kande (2016), outros trabalhos utilizam modelos deformáveis, é o caso de Mary et al. (2015), Li e Chutatape (2003), Novo et al. (2009), Esmaeili et al. (2012), Cheng et al. (2013), Hajer et al. (2008). Mary et al. (2015) utilizam *gradient vector flow* (GVF), Li e Chutatape (2003) utilizam PCA para inicializar o *active shape model* (ASM). Novo et al. (2009) usam modelos deformáveis que fazem a segmentação baseada em região e em borda ao mesmo tempo, o método é chamado de *Topological Active Nets* (TAN). Neste trabalho, algoritmos genéticos são empregados para prover a otimização do algoritmo de segmentação, ocasionando um bom desempenho até mesmo em imagens de fundo de olho com lesões. Esmaeili et al. (2012) utilizam transformada digital curvelet, modificando os coeficientes na imagem resultante da transformada sob o critério da esparsidade. Outros trabalhos que também fazem uso de modelos deformáveis incluem Cheng et al. (2013), Hajer et al. (2008).

Hsiao et al. (2012) utilizam um operador de correção de iluminação e GVF supervisionado para obter um contorno mais preciso do disco, informações estatísticas extraídas da imagem de treinamento são usadas na classificação dos pixels durante as iterações do GVF supervisionado. O resultado é de 95% de localização correta na base DRIVE e 91% de bordas corretamente

segmentadas.

Budai et al. (2013a) aplica a *fast radial symmetry transform*, transformada de Hough e *fast radial symmetry transform* adaptada para delimitar o disco óptico, obtendo melhores resultados em sua adaptação, o erro médio observado chega a ser 4 vezes menor que nos outros métodos.

Considerando os trabalhos que utilizam conjuntos aproximativos para identificar o disco óptico, pode-se destacar os trabalhos de Mookiah et al. (2013a), Mookiah et al. (2013b) e Karkuzhali et al. (2015), que adotam *Atanassov's Intuitionistic Fuzzy Set* histon. Esta abordagem possui a vantagem de que o histograma e o histon gerados levam em consideração a relação espacial entre os pixels e também, o uso de função gaussiana de pertinência introduz significativa melhoria na detecção do disco óptico.

Métodos supervisionados de classificação de pixels também são bastante importantes na segmentação do disco óptico. Muramatsu et al. (2011b) faz um comparativo entre *Artificial Neural Network* (ANN), *Active Contour Model* (ACM), e *fuzzy c-mean* (FCM), e os melhores resultados são verificados para ANN. A métrica utilizada é obtida da comparação do resultado da segmentação com a demarcação feita por um oftalmologista.

Dashtbozorg et al. (2015) utiliza *multiresolution sliding band filter* para segmentar o disco óptico, seu algoritmo trabalha reduzindo a região de interesse a medida que respostas máximas do filtro são encontradas, 44% dos resultados são excelentes quando comparados a segmentação manual, 47% são bons e em 9% ocorre falha.

Uma abordagem adicional é o uso de descritores de textura em função da vascularização do disco óptico. Rao et al. (2015) utilizam um descritor de textura - a energia, combinada com informações estruturais para segmentar o disco óptico. Acharya et al. (2015) aplica a transformada de Gabor e extrai diversas características dos coeficientes, tais como média, curtose, energia, entropia, dentre outros.

4.2 Segmentação dos vasos sanguíneos

A correta determinação da localização dos vasos sanguíneos diminui os falsos positivos para microaneurismas, favorecendo o diagnóstico automático de retinopatia diabética e a segmentação deles é fundamental no diagnóstico auxiliado por computador em doenças como degeneração macular relacionada a idade, na própria retinopatia diabética e na retinopatia da prematuridade. A principal dificuldade de separar os vasos sanguíneos do restante é que eles

possuem um baixo contraste local inviabilizando o uso de métodos de detecção de bordas (CHAUDHURI et al., 1989; MARTINEZ-PEREZ et al., 2007).

Existem cinco³ classes de métodos para segmentação da estrutura vascular, que são: algoritmos baseados em rastreamento (*tracking*), algoritmos baseados em modelos (*matched filtering*), algoritmos baseados em classificação supervisionada de pixels, algoritmos baseados em modelos deformáveis e algoritmos baseados em morfologia matemática. Cada uma destas classes são discutidas a seguir.

4.2.1 Segmentação dos vasos sanguíneos por rastreamento

O **rastreamento** é semelhante ao que um oftalmologista faz ao examinar o fundo de olho de um paciente: inicialmente é escolhido um ponto de partida, por exemplo o disco óptico, e então inspeciona-se a vascularização da retina. Algoritmos que usam esta abordagem costumam fazer uso da recursividade devido a natureza repetitiva dos vasos sanguíneos e suas bifurcações. O procedimento padrão consiste em determinar um pixel (*seed*) de um vaso sanguíneo e realizar em seguida o crescimento de regiões, no qual os pixels mais próximos são agregados a cada etapa, ao término deste processo é obtida uma aproximação da vascularização.

Vlachos e Dermatas (2010) e Nayebifar e Moghaddam (2013) apresentam trabalhos seguindo esta abordagem. Farokhian e Demirel (2014) utilizam um banco com 180 filtros de Gabor para encontrar os vasos sanguíneos facilitando o uso de *thresholding*. Farnell et al. (2008) utiliza um operador de linha multiescala para encontrar os vasos sanguíneos.

Embora este tipo de algoritmo resolva o problema de uma maneira bastante natural, outras classes de algoritmos tem sido mais utilizadas. Possíveis desvantagens destes algoritmos são: a necessidade de se determinar *thresholds* que separem os vasos do fundo restante e a necessidade de determinação do ponto inicial (WANG et al., 2007).

4.2.2 Segmentação dos vasos sanguíneos por modelos - *matched filtering*

Uma das abordagens mais utilizadas em segmentação de vasos sanguíneos é a aproximação de tais vasos por meio de modelos matemáticos. Assim, o objetivo dos algoritmos baseados em **modelos** é obter uma formulação matemática que aproxime a tortuosidade dos vasos, isso é feito por meio de propriedades ópticas e espaciais dos vasos sanguíneos e utiliza *kernel* gaussiano

³Diferentes formas de classificar os métodos podem encontradas na literatura, Fraz et al. (2012b), Mookiah et al. (2013c) e Zaki et al. (2016) apresentam dissonâncias quanto a esta questão, assim, a classificação apresentada por Mookiah et al. (2013c) foi adotada por apresentar nível adequado de detalhamento para este trabalho.

2D, filtro de Gabor 2D e *templates* direcionais que realçam os vasos por meio da convolução do *kernel* com a imagem. Este método, também chamado de *matched filter response* (filtro adaptado), foi proposto por Chaudhuri et al. (1989) e tem sido muito utilizado e aprimorado ao longo dos anos, uma vez que em sua formulação original possui alto custo computacional e problemas com vasos muito finos ou muito grossos e ainda, os com muita tortuosidade.

Nesta classe de métodos, as principais tendências são: ajuste eficiente de parâmetros, uso de multi-escala e mudanças no *kernel*. Alguns métodos adotam mais de uma destas medidas para garantir melhorias, por exemplo, Wang et al. (2007) apresentam uma análise da vascularização da retina por meio de modelo Hermitiano-Gaussiano multiresolução, em que um modelo polinomial de intensidade hermitiano-Gaussiano é desenvolvido com perfis de vasos sanguíneos em um estrutura *quad-tree* contendo várias resoluções espaciais, com isso torna-se viável uma análise mais robusta. Sreejini e Govindan (2015) utilizam *Particle Swarm* para ajustar parâmetros do *matched filter* multi-escala visando supressão de ruído durante o processo de obtenção dos vasos sanguíneos; Wang et al. (2013) utilizam um *kernel multiwavelet* com decomposição hierárquica multi-escala que reduz ruído ao passo que localiza os vasos, além disso, fazem a análise da condição necessária para atingir a decomposição ótima.

Em algumas situações as melhorias são providas no pré ou pós-processamento pois algoritmos baseados em modelos podem ter problemas com ruído e com o reflexo de luz nos vasos sanguíneos (Figura 2.6). Outras contribuições relevantes incluem: uso de método híbrido de *matched filter* e colônia de formigas por Cinsdikici e Aydın (2009); Al-Rawi e Karajeh (2007) usam algoritmos genéticos para ajustar parâmetros; *kernel fuzzy c-means* para melhorar o extração dos vasos sanguíneos, obtendo bons resultados por Kar e Maity (2016); O resultado é de 72.46% de verdadeiros positivos e 3.45% de falsos positivos na base DRIVE (STAAL et al., 2004). Kovács e Hajdu (2016) apresentam um método baseado em *template matching* e reconstrução de contorno, em que uma função generalizada de Gabor é utilizado no *template matching* extraíndo-se o centro das linhas dos vasos.

Poucos trabalhos adotam *kernel* com outras distribuições probabilísticas. Assim, uma abordagem totalmente nova em *matched filtering* aplicado a segmentação de vasos sanguíneos em imagens do fundo de olho é apresentada por Singh e Srivastava (2016) que utiliza *kernel* com distribuição probabilística Gumbel, combinado com pré-processamento por PCA e equalização adaptativa do histograma e pós-processamento por filtro de comprimento e *thresholding* ótimo baseado em entropia. Singh e Srivastava demonstram a superioridade de seu método em relação

ao *matched filtering* com *kernel* Gaussiano em seus experimentos.

4.2.3 Segmentação dos vasos sanguíneos por classificação supervisionada de pixels

De maneira geral, os métodos de segmentação de vasos sanguíneos podem ser divididos em métodos supervisionados e não supervisionados. Métodos não supervisionados usam apenas as informações disponíveis na imagem capturada, geralmente requerem um grande conjunto de amostras para construção do modelo ideal. Enquanto que métodos supervisionados são baseados em informações rotuladas manualmente em vaso e não-vaso, a partir dessa marcação, um modelo é treinado e usado para segmentar outras imagens. Há também métodos semi-supervisionados, que são menos dependentes de informações rotuladas.

O trabalho pioneiro em segmentação de vasos sanguíneos por método supervisionado foi apresentado por Nekovei e Sun (1991), trata-se de uma rede neural artificial com uma abordagem de retropropagação, usada em imagens angiográficas.

Algoritmos baseados em **classificação supervisionada de pixels** são voltados principalmente para redes neurais artificiais, é o caso de Marin et al. (2011), Franklin e Rajan (2014a), Franklin e Rajan (2014b) e podem incluir o uso de *forward selection*, Staal et al. (2004); regra delta modificada, Nekovei e Sun (1995); *Convolutional Neural Network* (CNN), Maji et al. (2016) e *Random Forest* (RF), Wang et al. (2015). Um outro classificador que também é utilizado é máquina de vetor suporte *Support Vector Machine* (SVM), Ricci e Perfetti (2007) aplicam SVM no vetor de características resultante do processamento da imagem por dois operadores de linha ortogonais para segmentar vasos sanguíneos.

Vega et al. (2015) utiliza uma *Lattice Neural Network with Dendritic Processing* (LNNDP) para segmentar os vasos sanguíneos e compara seu método com SVM e perceptrons multicamadas observando melhores resultados em seu método. O LNNDP proposto pode resolver um problema específico sem a necessidade de supervisionar os parâmetros da rede, resultando em uma sensibilidade de 0,7444, especificidade de 0,9600 e uma precisão de 0,9412.

Maji et al. (2016) utiliza uma rede neural convolucional profunda para segmentar vasos sanguíneos em imagens da retina. Um conjunto de 12 redes convolucionais neurais é treinado usando imagens não pré-processadas. Como resultado, uma precisão de 0,9470 é obtida.

Hassanien et al. (2015) propõe um algoritmo que utiliza otimização baseada em colônias de abelhas em conjunto com a função de adequação de compacidade *fuzzy cluster*. A sensibilidade

alcançada pelo método é de 0,7210, a especificidade de 0,9710 e a precisão de 0,9388. Orlando e Blaschko (2014) usam um modelo de campo aleatório condicional totalmente conectado para treinar e segmentar a estrutura vascular da retina. Os resultados encontrados no banco de dados DRIVE mostram uma sensibilidade de 0,785 com um desvio padrão de 0,045 e uma especificidade de 0,967 com um desvio padrão de 0,007.

O trabalho de Chen et al. (2016) propõe uma abordagem bastante inovadora para prover melhorias em imagens de retina ao tratar a questão como um problema de aprendizado de dicionário. Neste contexto, sinais são descritos como combinações lineares dos sinais atômicos que compõem o dicionário. Em um dicionário *overcomplete* a quantidade de átomos é maior que o tamanho das informações de entrada. Chen et al. (2016) utilizam dois dicionários *overcomplete* para obter a estrutura dos vasos, o *Representation Dictionary* e o *Enhancement Dictionary*. O *Representation Dictionary* é a representação das imagens originais com codificação esparsa, enquanto que o *Enhancement Dictionary* é gerado a partir das imagens rotuladas. Inicialmente, as imagens são representadas com o *Representation Dictionary*, em seguida são reconstruídas por meio da obtenção de coeficientes esparsos e do *Enhancement Dictionary*. O resultado é a imagem com os vasos sanguíneos realçados possibilitando a segmentação por simples limiarização.

4.2.4 Segmentação dos vasos sanguíneos por modelos deformáveis

A abordagem fundamentada em **modelos deformáveis** utiliza princípios físicos para simular o comportamento de objetos reais, pode adotar uma metodologia paramétrica ou geométrica. Considerando a segmentação dos vasos sanguíneos, é uma classe de métodos menos utilizada que *matched filtering* e classificação supervisionada, porém, tais métodos são de grande importância devido a maneira que tratam o problema, sua maior aplicabilidade é em sequências de vídeo (SILVA, 2010).

Modelos paramétricos são baseados em ACM, essa categoria de modelos deformáveis estabelece curvas na imagem que são movidas em função da influência dos dados locais até que um dado critério de convergência seja atingido, é possível realizar este processo de maneira supervisionada ou não. Já os modelos geométricos utilizam técnicas numéricas para implementar preceitos da teoria de evolução da curva em fluxos geométricos.

Rivest-Henault et al. (2010) e Zhao et al. (2014) apresentam trabalhos que fazem uso de *active contour models*. Este último realiza várias etapas de pré-processamento, são aplicados: a equalização adaptativa do histograma, o filtro de gabor 2D e filtro anisotrópico para suavização

da imagem para então aplicar o *active contour models*. Sum e Cheung (2008) apresentam uma abordagem de modelo deformável geométrico que manipula imagens com iluminação não-uniforme, já que este é um grande problema em imagens da retina. Martinez-Perez et al. (2007) usam a primeira e segunda derivadas do *kernel* Gaussiano com um fator de escala para garantir a extração de características geométricas da imagem de fundo do olho, com isso é possível inferir sobre a topologia dos vasos sanguíneos, o tensor hessiano é usado em múltiplos passos de crescimento de regiões resultando em vasos sanguíneos segmentados.

Outras possibilidades em modelos deformáveis incluem multiconcavidade e inundação de água. Como exemplo destes, tem-se o trabalho de Lam et al. (2010) que usa o modelo multiconcavidade e Asad et al. (2013) que utilizam uma abordagem baseada em inundação de água que conta também com etapas de evaporação e resulta em vasos realçados.

4.2.5 Segmentação dos vasos sanguíneos por morfologia matemática

A **Morfologia matemática** também é muito utilizada na segmentação de vasos sanguíneos, trata-se de uma metodologia baseada em teoria de conjuntos para remover, acrescentar ou gerar informações. Sua principal construção é a aplicação sistemática de um elemento estruturante que resulta em uma nova imagem com as informações removidas ou adicionadas. Também se incluem nessa categoria os métodos baseados em esqueletos e fecho convexo que são utilizados para descrever formas.

Alguns algoritmos fazem uso da morfologia matemática de maneira pura, é o caso de Zana e Klein (2001) que ajusta o elemento estruturante para contemplar os vasos e suas bifurcações e Rodríguez et al. (2005) que utiliza *watershed* morfológica em dois passos, o primeiro que aproxima os vasos e o segundo que os segmenta, porém, é mais comum encontrar a morfologia matemática associada à outros métodos, ou como um critério de decisão para a localização dos vasos sanguíneos. É o caso de Fraz et al. (2012a) que extrai as linhas centrais dos vasos sanguíneos utilizando a derivada de primeira ordem de um filtro gaussiano e em seguida realiza a avaliação da derivada por meio de uma mapa obtido do fatiamento morfológico do plano de bits.

Porém, o principal uso da morfologia matemática é na forma de pré ou pós-processamento. Muitos dos algoritmos de rastreamento e de classificação supervisionada de pixels e até alguns de *matched filtering* usam afinamento como pós-processamento para obter informações sobre conectividade melhorando o resultado final da segmentação dos vasos sanguíneos. É impor-

tante destacar que esta classe de método possui problemas com o ruído presente nas imagens. Assim, uma alternativa menos suscetível ao ruído é a esqueletonização, geralmente feita por Transformada do Eixo Medial - *Medial Axis Transform* (MAT) (SANTOS, 2007).

4.2.6 Segmentação dos vasos sanguíneos por outros métodos e considerações gerais

Alguns métodos não se enquadram exatamente nas classes discutidas, dentre eles Rodríguez et al. (2008) apresenta dois, *mean shift* e método espectral. Em seu trabalho, Rodríguez faz comparação entre ambos tomando como medida o número de vasos obtidos em contraste com a segmentação manual. Observa-se que *mean shift* possui menor índice de falsos positivos, 20% enquanto que o método espectral resulta em 45%, ambos não geram falsos negativos. Koukounis et al. (2014) apresenta uma solução baseada em hardware para prover rapidez ao *matched filtering*. Tsai et al. (2015) propõe uma função de transformação característica adaptativa para segmentar vasos sanguíneos em angiogramas.

A tabela 6.3 mostra um comparativo entre diversos métodos apresentados na literatura. Verifica-se que as principais bases são a DRIVE e STARE, e ainda, que as principais medidas de desempenho dos métodos de segmentação são a sensibilidade, a especificidade, a precisão e a ROC.

4.3 Trabalhos correlatos

Dentre os trabalhos citados anteriormente, alguns possuem semelhança com o presente trabalho e por isso serão discutidos nesta seção. Tais trabalhos foram agrupados em três categorias contemplando a segmentação de imagens de fundo de olho: localização do disco óptico, segmentação do disco óptico e segmentação dos vasos sanguíneos.

4.3.1 Trabalhos correlatos em localização do disco óptico

Um trabalho a ser destacado em localização do disco óptico é apresentado por Abdullah et al. (2016), em que se realiza a localização por meio de transformada de Hough circular.

Inicialmente Abdullah et al. seleciona o canal verde devido a seu grande contraste e realiza operações para normalizar o contraste e a iluminação. Em seguida, operações morfológicas são aplicadas para remover os vasos sanguíneos presente na imagem, sendo que é escolhido o fechamento com elemento estruturante na forma de disco com raio 5. Feito isto, é aplicada a

transformada de Hough circular clássica para detectar o centro do círculo correspondente ao disco óptico.

Como a transformada de Hough se baseia na equação da circunferência, alguns parâmetros devem ser pré-determinados, no caso, uma estimativa inicial para o raio do disco óptico é fixada em 29 a 50 pixels. A transformada de Hough é aplicada sucessivamente com diferentes graus de sensibilidade, até que um bom candidato a centro do disco seja encontrado. No capítulo 6 os resultados apresentados por Abdullah et al. (2016) são comparados aos resultados obtidos.

4.3.2 Trabalhos correlatos em segmentação do disco óptico

A segmentação do disco óptico no presente trabalho utiliza *roughness index*, assim como o trabalho de Mookiah et al. (2013b). Outros estudos trazem variações na técnica e também são abordados adiante, é o caso de Chiranjeevi e Sengupta (2012) e Xie et al. (2015), que não se aplicam exatamente a segmentação de imagens de fundo de olho, mas que apresentam importantes contribuições. A teoria sobre *rough sets* foi apresentada na seção 3.7, e a segmentação baseada em *roughness index* na seção 3.8.

Mookiah et al. (2012) e Mookiah et al. (2013b) apresentam a segmentação do disco óptico baseada em *intuitionistic fuzzy histon*, conforme discutido na seção 3.7.1. Inicialmente é feito o pré-processamento utilizando *Contrast Limited Adaptive Histogram Equalization* (CLAHE). A seguir os vasos sanguíneos são removidos com filtro de Gabor 2D com 12 *templates* rotacionados em 15°. Esta etapa é finalizada com operação morfológica de fechamento com elemento estruturante na forma de disco de tamanho 15×15 .

A próxima etapa é a localização do disco óptico, que é feita com o auxílio de *Column Wise Neighborhood Operation* (CWNO), no qual a imagem é processada utilizando a vizinhança dos pixels em colunas. O resultado do processamento é uma imagem contendo bordas e o disco óptico, nesta imagem são aplicadas as operações: limiarização, dilatação e erosão. A parte mais clara da imagem é escolhida e então gera-se uma máscara contemplando toda a região que esteja dentro do raio de 150 pixels, a partir do ponto determinado.

Por último é realizada a segmentação do disco óptico com uso de A-IFS Histon. Esta técnica foi aprimorada ao longo dos anos, sendo que a referência para a mesma é o trabalho de Mushrif e Ray (2009), em que o histograma e histon das imagens são utilizados como aproximações *Lower* e *Upper*, respectivamente, conforme discutido na seção 3.7. Por meio do *roughness index* obtém-se os picos a partir dos quais são determinados os vales. Cada vale define

um *threshold* usado para separar a imagem em diversas partes. Ao final é obtido um percentual de 93,4% de precisão em uma base de imagens própria.

Xie et al. (2015) trabalham com a segmentação de imagens médicas por meio de *rough sets* de maneira semelhante a Mookiah et al. (2013b). No entanto, destacam a forte presença de ruído, a baixa separabilidade dos tecidos, dentre outros problemas inerentes as imagens médicas. Por isso, supõem que fixar os valores utilizados pelo algoritmo na obtenção de picos do *roughness index* pode não ser adequado para todas as imagens. A solução apresentada consiste da suavização do histon e do histograma por meio de *Local Polynomial Regression* (LPR), gerando um *roughness index* mais suave. Em função da suavidade do *roughness index* picos pouco significativos são eliminados, e o algoritmo de detecção de picos e vales segue um novo formato, conforme seção 4.3.2.

Xie et al. testam a segmentação por meio de histograma, histon, *roughness index*, *roughness index* com média móvel e *roughness index* suavizado por LPR. Nos resultados é possível observar a redução no número de *thresholds* obtidos na segmentação, principalmente na presença de ruído. Em um dos experimentos, 20 imagens de tomografia computadorizada do abdômen são submetidas aos métodos de segmentação com a finalidade de segmentar o fígado, o rim direito e o baço. O resultado de maior significância é observado em *roughness index* suavizado por LPR que resulta em 0,92, 0,89 e 0,89 respectivamente, considerando a medida DSM.

Chiranjeevi e Sengupta (2012) aplicam *rough sets* na detecção de objetos em movimentos em sequências de vídeo. Uma das maneiras de se realizar esse tipo detecção é a subtração de fundo, e para tal, é necessário possuir um modelo consistente de classificação dos pixels, que informe se ele está no fundo ou se pertence ao objeto. Como o *roughness index* traz a variação entre os pixels e seus vizinhos, Chiranjeevi e Sengupta usam essa ferramenta para rotular os pixels que pertencem ao fundo e os que pertencem ao objeto. Espera-se que o fundo apresente pouca variação em relação aos frames próximos enquanto os pixels do objeto apresentam grande variação. Assim, a distância de Bhattacharyya é calculada entre o *roughness index* obtido e os novos frames. Chiranjeevi e Sengupta também desenvolveram e aplicaram o conceito de histograma 3D, que gera uma melhor correlação entre as cores presentes no objeto, conforme discutido na seção 27.

Para validar o método, são feitos experimentos com *roughness index 3D* e *fuzzy roughness index 3D* em 8 sequências de vídeos, com quantização para reduzir o tamanho do histograma e histon. A *F-measure* é exibida para cada sequência, em que se observa grande superioridade do

método proposto em relação a outros métodos.

Rough set e regressão polinomial local

Xie et al. (2015) apresenta uma formulação aprimorada do uso de *roughness index*, em seu trabalho destaca o uso desta ferramenta em imagens médicas e fala sobre a dificuldade em obter picos e vales, uma vez que o algoritmo de segmentação proposto por Mushrif e Ray (2008) utiliza valores fixos determinados por meio de experimentação, por exemplo, a distância entre picos deve ser de no mínimo 10 e estes são 20% acima da média.

De acordo com Xie et al. (2015), inicialmente, considera-se o histograma em escala de cinza como sendo constituído de L pares de observações, $(1, h(1)), (2, h(2)), \dots, (L, h(L))$, com isso o histograma pode ser redefinido como:

$$h(g) = \mu(g) + \varepsilon_g (1 \leq g \leq L) \quad (4.1)$$

onde $\mu(g)$ é uma função conhecida e ε_g é um termo de erro. Os erros $\varepsilon_g (1 \leq g \leq L)$ são assumidos como identicamente distribuídos.

O próximo passo é estimar os valores do histograma dentro de um pequeno intervalo de forma que seja obtida sua suavização, para isso é utilizado o teorema de Taylor e janelas. O teorema de Taylor afirma que qualquer função diferenciável pode ser aproximada localmente. Assim, dada uma função de largura de banda $b(x)$, define-se a função peso $\omega_g(x)$, utilizando uma janela de suavização $(x - b(x), x + b(x))$:

$$\omega_g(x) = K\left(\frac{g - x}{b(x)}\right) \quad (4.2)$$

a função $\omega_g(x)$ atribui os maiores pesos dentro da observação próxima a x . O kernel utilizado é:

$$K(u) = \frac{1}{\sqrt{2\pi}} e^{-\frac{u^2}{2}} \quad (4.3)$$

Na janela suavizada, $\mu(u)$ é aproximada pelo polinômio:

$$\mu(u) \approx a_0 + a_1(u - x) + \frac{1}{2}a_2(u - x)^2 + \dots + \frac{a_r}{r!}(u - x)^r \quad (4.4)$$

caso $|u - x| < b(x)$, o polinômio poderá ser dado por uma notação compacta:

$$\mu(u) \approx a_0 + a_1(u - x) + \frac{1}{2}a_2(u - x)^2 + \dots + \frac{a_r}{r!}(u - x)^r = \langle a, A(u - x) \rangle \quad (4.5)$$

onde $A(\cdot)$ é um vetor de funções de ajuste e a é um vetor de coeficientes que pode ser estimado minimizando a soma ponderada:

$$\sum_{g=1}^L \omega_g(x) \left(h(g) - \langle a, A(g-x) \rangle \right)^2 \quad (4.6)$$

Conforme Xie et al. (2015), esta solução pode ser escrita como:

$$\hat{\beta} = \left(\Delta_x^T W_x \Delta_x \right)^{-1} \Delta_x^T W_x H \quad (4.7)$$

onde $H = (h(1), h(2), \dots, h(L))$, W_x é uma matriz $L \times L$ cuja diagonal é constituída por pesos, tal que $w_{gg}(x) = w_g(x)$, e Δ_x é dada por:

$$\Delta_x = \begin{bmatrix} 1 & 1-x & \dots & \frac{(1-x)^r}{r!} \\ 1 & 2-x & \dots & \frac{(2-x)^r}{r!} \\ \vdots & \vdots & & \vdots \\ 1 & L-x & \dots & \frac{(L-x)^r}{r!} \end{bmatrix} \quad (4.8)$$

O estimador $\hat{\mu}(x)$ é o coeficiente interceptado $\hat{\beta}$ do ajuste local, e pode ser escrito como:

$$\hat{\mu}(x) = e_1^T \left(\Delta_x^T W_x \Delta_x \right)^{-1} \Delta_x^T W_x H \quad (4.9)$$

onde $e_1^T = (1, 0, \dots, 0)$ é um vetor de dimensão $(r+1) \times 1$, resultando em:

$$\hat{\mu}(x) = \sum_{i=1}^L l(x) h(i) \quad (4.10)$$

onde $l(x)^T = e_1^T \left(\Delta_x^T W_x \Delta_x \right)^{-1} \Delta_x^T W_x$.

O erro ε_g é desprezado, com isso o histograma suavizado por LPR é:

$$\hat{h}(g) = \hat{\mu}(g) \quad (1 \leq g \leq L) \quad (4.11)$$

O Histon suavizado é dado pela Equação 4.11 substituindo o histograma pelo histon na Equação 4.10.

É fundamental utilizar uma boa estimativa para a largura da janela, do contrário não será obtida a suavização necessária no histograma ou a suavização pode ser excessiva ao ponto de perder informações. Xie et al. (2015) sugere o uso do método de Bowman e Azzalini's para estimar a largura da janela:

$$b^* = \left(\frac{4}{3L}\right)^{\frac{1}{5}} \sigma \quad (4.12)$$

onde σ é a variância de H .

Com o histograma e o histon suavizados calcula-se o *roughness index*:

$$\hat{\rho}(g) = 1 - \frac{\hat{h}(g)}{\hat{H}(g)} \quad (4.13)$$

para $1 \leq g \leq L$

Com a nova forma de *roughness index*, um novo algoritmo de *thresholding* é definido para se beneficiar da suavidade da curva gerada, Algoritmo 3. No algoritmo citado, um pico é qualquer valor do *roughness index* que seja maior que seu antecessor e seu sucessor, e vale é um valor do *roughness index* que seja menor que seu antecessor e seu sucessor. Inicialmente, o algoritmo encontra os picos e os vales; em seguida, exclui picos e vales que não estejam em curvas suaves, o critério para isso é que o antecessor e o sucessor devem ser iguais. O último passo é a ordenação dos vales em ordem ascendente.

Xie et al. (2015) sugere que os principais esforços no ajuste do método sejam quanto à largura da janela, uma vez que o grau do polinômio não precisa ser alto, em seus resultados, mostram bom desempenho para o $r = 2$.

Algoritmo 3: Segmentação com *roughness index* suavizado

```

input : Roughness Index suavizado  $\widehat{RI}$ 
output : Thresholds correspondentes aos vales significantes do  $\widehat{RI}$ 

1 begin
   /* Inicialmente encontra se os picos                                */
2    $j \leftarrow 1$ ;
3   foreach posição  $i$  em  $\widehat{RI}$  do
4     if ( $\widehat{RI}(i) > \widehat{RI}(i-1)$ ) & ( $\widehat{RI}(i) > \widehat{RI}(i+1)$ ) then
5       picos( $j$ )  $\leftarrow i$ ;
6        $j \leftarrow j + 1$ ;
7     end
8   end
   /* Em seguida encontra se os vales                                */
9    $j \leftarrow 1$ ;
10  foreach posição  $i$  em  $\widehat{RI}$  do
11    if ( $\widehat{RI}(i) < \widehat{RI}(i-1)$ ) & ( $\widehat{RI}(i) < \widehat{RI}(i+1)$ ) then
12      vales( $j$ )  $\leftarrow i$ ;
13       $j \leftarrow j + 1$ ;
14    end
15  end
   /* Remova picos e vales que não atendam aos critérios:            */
16  foreach pico  $p$  na posição  $i$  do  $\widehat{RI}$  do
17    if ( $\widehat{RI}(i+1) \neq \widehat{RI}(i-1)$ ) then
18      picos  $\leftarrow$  removePico( $\widehat{RI}$ , picos,  $i$ );
19    end
20  end
21  foreach vale  $v$  na posição  $i$  em  $\widehat{RI}$  do
22    if ( $\widehat{RI}(i+1) \neq \widehat{RI}(i-1)$ ) then
23      vales  $\leftarrow$  removeVale( $\widehat{RI}$ , vales,  $i$ );
24    end
25  end
26  vales  $\leftarrow$  orden(vales, 'ascendente');
27 end

```

Histograma e histon 3D

Na abordagem apresentada por Chiranjeevi e Sengupta (2012) define-se o histograma 3D, que é uma estrutura que agrega os canais RGB, gerando uma maior correlação entre os componentes das cores. Sua obtenção se dá por meio da Equação 4.14:

$$h_{3D}(i, j, k) = \sum_{m=1}^M \sum_{n=1}^N \delta(I(m, n) - (i, j, k)), \text{ para } 0 \leq i \leq l_1 - 1, \quad (4.14)$$

$$0 \leq j \leq l_2 - 1, 0 \leq k \leq l_3 - 1$$

Analogamente obtém-se o histon 3D:

$$H_{3D}(i, j, k) = \sum_{m=1}^M \sum_{n=1}^N (1 + X(m, n)) \delta(I(m, n) - (i, j, k)), \text{ para } 0 \leq i \leq l_1 - 1, \quad (4.15)$$

$$0 \leq j \leq l_2 - 1, 0 \leq k \leq l_3 - 1$$

$X(m, n)$ permanece como definido em 3.17, assim como o *roughness index* segue a definição apresentada na Equação 3.24.

O método foi proposto em função da observação de que muitas técnicas em processamento de imagens coloridas tratam os canais de maneira independente, ignorando-se o fato de que eles são dependentes dentro dos contextos a serem tratados. Pode-se citar aqui o exemplo do disco óptico em imagens de fundo de olho em que se espera grande intensidade do vermelho, um pouco menos de verde e quase nada de azul.

Chiranjeevi e Sengupta também estendem seu trabalho ao uso de *fuzzy histon*, Equação 3.30. Assim como definido anteriormente, a função $X(m, n)$ é substituída por uma função de pertinência gaussiana, Equação 3.31. A Figura 4.1 ilustra o processo de obtenção do histon e histograma 3D. Inicialmente um fragmento artificial de imagem RGB é dado, Figura 4.1(a). Em seguida a matriz de similaridade $X(m, n)$ é calculada utilizando o valor de expansão $S_{th} = 10$, Figura 4.1(b). Com isso a matriz de similaridade $\tilde{X}(m, n)$ pode ser obtida com base em função gaussiana com $\sigma = 10$, Figura 4.1(c). O histon básico é obtido a partir da matrix de similaridade, considerando cada canal em separado, Figura 4.1(d). Por último é mostrada a obtenção do histon 3D e fuzzy histon 3D, em que o índice é calculado a partir da fórmula $n = 16i + 4j + k$, considerando que o exemplo contém apenas 4 níveis de intensidade, está fórmula pode ser generalizada para $n = L^2i + Lj + k$, em que L é a quantidade de níveis de intensidade presente na imagem e i, j, k são os índices dentro de cada canal de cor.

Figura 4.1: Geração do histograma 3D, histon 3D e fuzzy histon 3D. Adaptado de Chiranjeevi e Sengupta (2012).

2	1	3	1	0
3	0	2	1	0
1	2	1	1	0
2	0	0	0	0
1	1	2	2	2

0	3	1	1	0
0	2	3	1	0
1	2	2	1	2
2	0	1	1	2
2	0	3	1	2

2	1	3	1	0
3	0	2	1	0
1	2	1	1	0
2	0	1	0	0
1	1	2	2	2

(a) Canais RGB

1	0	0	1	1
0	0	0	0	1
1	0	0	0	1
1	0	0	0	1
1	0	0	0	1

0,715	0,373	0,281	0,682	0,942
0,293	0,067	0,238	0,518	0,772
0,611	0,308	0,478	0,542	0,811
0,663	0,122	0,379	0,304	0,693
0,842	0,570	0,282	0,542	0,792

	0	1	2	3
R	12	11	10	2
G	9	10	13	3
B	11	12	10	2

(b) Matriz similaridade X para histon ($S_{th} = 10$)

(c) Matriz similaridade \tilde{X} para fuzzy histon ($\sigma = 10$)

(d) Histon básico para cada canal

Índice	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Histon 3D	5	0	0	0	1	1	0	0	5	0	0	0	0	0	0	0
Fuzzy Histon 3D	4,84	0	0	0	1,3	1,38	0	0	4,57	0	0	0	0	0	0	0

Índice	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31
Histon 3D	0	1	0	0	0	6	0	0	0	3	0	0	0	1	0	0
Fuzzy Histon 3D	0	1,57	0	0	0	6,35	0	0	0	3,32	0	0	0	1,37	0	0

Índice	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47
Histon 3D	0	0	2	0	0	0	1	0	0	0	5	0	0	0	2	0
Fuzzy Histon 3D	0	0	1,71	0	0	0	1,54	0	0	0	4,76	0	0	0	2,52	0

Índice	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63
Histon 3D	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0	0
Fuzzy Histon 3D	0	0	0	1,29	0	0	0	1,28	0	0	0	0	0	0	0	0

(e) Histon 3D e fuzzy histon 3D, considerando os canais RGB combinados (o índice é dado por $n = 16i + 4j + k$, devido aos 4 níveis de intensidade)

4.3.3 Trabalhos correlatos em segmentação dos vasos sanguíneos

Um trabalho relevante em classificação supervisionada é apresentado por Soomro et al. (2017), que sugere uma rede neural convolucional para segmentar os vasos sanguíneos. Além da CNN Soomro et al. aplicam estratégias de pré-processamento para melhorar o estágio de treinamento, resultando em uma avaliação de sensibilidade de 0,746 e uma precisão de 0,946 no banco de dados DRIVE. O pré processamento neste trabalho é fundamental para garantir um bom aprendizado, uma vez que a distinção entre o fundo retiniano e os vasos finos não é trivial. A abordagem adotada consiste em técnicas baseadas em morfologia e escala de cinza, iniciando por aproximação bottom-hat (fechamento morfológico seguido de subtração da imagem original) e depois top-hat (subtração entre a imagem original e sua abertura), a subtração entre as imagens bottom-hat e top-hat é realizada para reduzir o ruído. Outro pré-processamento empregado é a conversão de RGB para escala de cinza empregando PCA para obter um contraste melhor. Pós-processamento também é empregado com base em limiarização e reconstrução morfológica afim de produzir uma imagem segmentada mais limpa, com o mínimo de pontos espúrios.

Liskowski e Krawiec (2016) utilizam aprendizado profundo em um conjunto de 400.000 amostras obtidas por meio de pré-processamento com normalização global de contraste, transformações geométricas e correções gama no banco de dados DRIVE. As transformações são aplicadas localmente tendo por base cada *patch*⁴, inicialmente é feita a normalização de contraste subtraindo a média de cada *patch* e fazendo a divisão pelo desvio padrão, independente dos canais R,G e B. Depois da normalização, é feito o Zero-phase Component Analysis (ZCA) que de maneira similar ao PCA, extrai as principais informações, mas que possibilita maior proximidade com os dados originais. Os resultados obtidos indicaram uma sensibilidade de 0,7819, especificidade de 0,9748 e uma precisão de 0,9472.

4.4 Considerações finais do capítulo

Este capítulo apresentou os principais estudos realizados em segmentação de imagens do fundo de olho, abordando a segmentação dos vasos sanguíneos e do disco óptico.

A segmentação do disco óptico é importante para que o mesmo não seja confundido com um exsudato e para que outras estruturas sejam localizadas. Diversas informações provenientes de estudos em oftalmologia auxiliam os métodos de segmentação. Métodos baseados em limiarização por nível de intensidade são rápidos, porém costumam falhar, uma vez que o disco

⁴No contexto citado, um *patch* corresponde a fragmento $3 \times 27 \times 27$

óptico encontra-se obstruído por vasos sanguíneos e possui o lado temporal mais claro que o nasal. Muitas vezes abordagens simples e rápidas são usadas para localizar o disco óptico enquanto que métodos mais robustos delimitam a fronteira do mesmo. Modelos deformáveis constituem-se na principal abordagem para obter um contorno preciso do disco óptico, muitos trabalhos usam *active contour model*. Por outro lado, a localização do disco é feita por PCA, transformada de Hough e outros métodos baseados em intensidade. Alguns métodos podem ser usados tanto na localização quanto na segmentação, neste caso alguns refinamentos são aplicados.

Métodos baseados em modelos deformáveis sofrem com baixo contraste e irregularidades decorrentes de anomalias; precisam de uma boa inicialização para obter alta precisão. Métodos baseados em aprendizagem não funcionam bem na presença de interferências que alteram a estrutura dos marcos anatômicos, pois seria necessário alimentar o conjunto de treinamento com muitas imagens, contemplando as mais diversas situações. Métodos baseados em informações geométricas da vasculatura também têm problemas com a alteração da estrutura dos vasos sanguíneos. Já métodos baseados em transformações circulares devem sempre estar associados a outros métodos em função da atrofia peripapilar e da forma do disco levemente oval.

A principal dificuldade na segmentação da imagem de fundo de olho é a eliminação da influência dos vasos sanguíneos que se estendem por toda a imagem e se sobrepõe a outras estruturas como o disco óptico, alguns pesquisadores usam técnicas de *inpainting* para contornar este problema. Outro dificultador é que os vasos possuem baixo contraste em relação ao fundo, por isso, é comum encontrar trabalhos que utilizam apenas o canal verde do RGB, afinal, neste canal o contraste em relação ao fundo é maior. Diversos trabalhos foram mencionados e verifica-se que o principal método adotado para segmentação dos vasos sanguíneos é o *matched filter* que vem sendo intensamente estudado nos últimos anos. Outras abordagens para a segmentação dos vasos sanguíneos são: *tracking*, morfologia matemática, modelos deformáveis, classificação supervisionada de pixels. Sendo este último também bastante utilizado.

O capítulo a seguir apresenta os métodos propostos.

CAPÍTULO 5

MÉTODOS PROPOSTOS

Este capítulo é organizado da seguinte forma: na seção 5.1 apresentamos a aquisição de imagens; na seção 5.2 apresentamos as técnicas usadas no pré-processamento das imagens; na seção 5.3 os principais fundamentos em localização do disco óptico; na seção 5.4 a segmentação do disco óptico, e na seção 5.5 a segmentação dos vasos sanguíneos.

5.1 Aquisição de imagens


Como foi dito na seção 3.3, neste trabalho são utilizadas imagens obtidas de bases públicas, particularmente: DIARETDB1, DRIVE, HRF, Messidor e STARE. Todas as bases escolhidas possuem exclusivamente imagens coloridas RGB, com 8 bits por canal. A maioria delas teve as imagens geradas digitalmente e com qualidade satisfatória.

A base com maior qualidade é a HRF, as imagens possuem pouca interferência do meio de aquisição, são centradas na mácula e em alta resolução. São fornecidas máscaras para a FOV e o padrão ouro para a segmentação dos vasos sanguíneos. A única observação em relação a esta base é quanto aos diferentes grupos de imagens, percebe-se uma leve variação na calibragem de iluminação do equipamento de aquisição: as imagens de olhos saudáveis são ligeiramente mais escuras que as imagens de olhos com retinopatia diabética. A base DRIVE também possui qualidade suficiente e informações sobre vasos sanguíneos, enquanto que a base Messidor possui a segmentação dos discos ópticos. Deve-se destacar a falta de padrão de aquisição na base Messidor, que é esperada por se tratar de uma base grande, obtida por diversos pesquisadores. A base DIARETDB1 representa um grande desafio devido à intensa variação na iluminação e baixo contraste. A tabela 5.1 descreve a maneira como cada base é utilizada neste trabalho.

Tabela 5.1: Uso de bases públicas de imagens pelo presente trabalho

Base	Uso		
	Localização do disco óptico	Segmentação do disco óptico	Segmentação de vasos sanguíneos
DIARETDB1	x		
DRIVE	x		x
HRF	x		
Messidor	x	x	

Deve-se destacar a grande variabilidade em termos de iluminação e contraste. A Figura 5.1 ilustra o problema: até dentro de uma mesma base a variação é intensa, existe retinografias com alto contraste contando com grande interferência das fibras nervosas e do humor aquoso, Figura 5.1(a), e também retinografias com baixíssimo contraste, Figura 5.1(e), cujo disco óptico se quer pode ser visualizado no canal vermelho, Figura 5.1(f). Portanto, técnicas destinadas ao presente contexto devem ser bastante genéricas ou possuir auto-adaptação.

Figura 5.1: Variação de contraste na base Messidor

(a) e (e) Imagens originais. (b)–(d) e (f)–(h) Respectivas decomposições R, G e B de (a) e (e).

5.2 Pré-processamento


O pré-processamento visa o provimento de melhorias nas imagens e é necessário em quase todos os contextos. Em imagens de fundo de olho há problemas com ruído, iluminação e contraste. Problemas de iluminação e contraste são inerentes a anatomia do olho: devido ao seu formato esférico, as extremidades se tornam sombreadas ou mais iluminadas conforme o ângulo e o foco adotados; vasos sanguíneos refletem a luz; e por fim, há também a grande vascularização da retina que gera baixo contraste dificultando a separação dos elementos.

Os métodos adotados no pré-processamento das imagens de fundo de olho devem produzir efeitos bastante sutis, do contrário detalhes como exsudatos, manchas algodonosas e vasos finos podem desaparecer ou serem demasiadamente realçados. Assim, no presente trabalho, o pré-processamento das imagens consiste da aplicação do filtro de Wiener 5×5 e filtro da mediana 3×3 afim de eliminar ruído e suavizar a imagem, também é realizado o ajuste de contraste. Foram feitos experimentos em RGB e CIE Lab, embora seja usual optar por CIE Lab, melhorias muito pequenas poderiam justificar o uso de RGB, pois assim elimina-se o custo da transformação entre modelos de cores. A vantagem de se utilizar CIE Lab é que o ruído e os problemas de iluminação são isolados no canal de luminância possibilitando o uso de técnicas para melhorá-los sem gerar distorções das cores (MOOKIAH et al., 2013a).


A Figura 5.2(a) mostra a imagem original obtida da base messidor, embora seja pouco perceptível, existe a presença de ruído e problemas de contraste, a grande intensidade no canal vermelho dificulta a separação entre o fundo e vasos sanguíneos. A Figura 5.2(b) contém a imagem pré-processada em RGB na qual se pode notar uma suavização do ruído, porém não há grandes melhorias no contraste, além disso os vasos sanguíneos foram excessivamente suavizados. A Figura 5.2(c) mostra a imagem pré-processada no modelo CIE Lab, é possível perceber que além da redução de ruído mais intensa a imagem se tornou mais clara, o vermelho fica menos evidente reforçando o contraste entre os vasos sanguíneos e o restante da retina.

As Figuras 5.3 e 5.4 mostram as etapas do pré-processamento CIE Lab e RGB respectivamente. Em imagens convertidas para CIE Lab, todos os procedimentos são realizados no canal da luminância, em ordem, aplica-se o filtro de Wiener, Figura 5.3(b), depois o filtro mediana, prosseguindo-se com o ajuste da luminância que leva este canal para o intervalo de 0 a 120, Figura 5.3(c). Após este procedimento, os três canais são reunidos e a imagem é novamente convertida em RGB, Figura 5.3(d), finalizando-se com o ajuste de contraste que leva a imagem para o intervalo de 0 a 255, Figura 5.3(e). Já em imagens RGB os passos do pré-processamento são os seguintes: inicialmente aplica-se o filtro de Wiener em cada um dos canais, Figura 5.4(b), fazendo-se a normalização do contraste por meio do ajuste da imagem no intervalo de 0 a 255, Figura 5.4(c), por último realiza-se a aplicação do filtro da mediana 3×3 , Figura 5.4(d). O ajuste de contraste, Equação 5.1, é feito em todos os canais simultaneamente para que não ocorra distorção das cores.


Figura 5.2: Pré-processamento das imagens



(a)




(b)



(c)

(a) Imagem original - base messidor, (DECENCIÈRE et al., 2014). **(b)** Imagem pré-processada em RGB.
(c) Imagem pré-processada em CIE Lab.

Figura 5.3: Etapas do pré-processamento das imagens em CIE Lab

(a) Imagem original - base DRIVE, (STAAL et al., 2004). (b) Luminância após aplicação do filtro de Wiener. (c) Luminância após filtro da mediana e ajuste de nível. (d) Imagem após junção da luminância com canais de cor e retorno ao modelo RGB. (e) Imagem RGB após ajuste de contraste.

$$I' = 255 * \frac{I - \min(I)}{\max(I - \min(I))} \quad (5.1)$$


em que I é a imagem de entrada e I' a imagem ajustada. As operações de máximo e mínimo são aplicadas nos três canais da imagem ao mesmo tempo, gerando um único máximo e um único mínimo para toda a imagem.

A fim de determinar a melhor opção de pré-processamento, foi realizado um teste envolvendo a próxima etapa que é a localização do disco óptico, Figura 5.5. Neste teste foram submetidas a imagem original, Figura 5.5(a), a imagem pré-processada em RGB, Figura 5.5(b), a imagem pré-processada em CIE Lab, Figura 5.5(c), e a imagem pré-processada em CIE Lab com correção de iluminação condicional, Figura 5.5(d). Tal correção é designada por correção de iluminação radial pois a correção no pixel se dá conforme o seu raio, quanto mais próximo ao centro da imagem, maior é a intensidade atribuída a luminância, para se obter este efeito utiliza-se uma curva, Figura 5.6.

No total, foram submetidas 1374 imagens das bases Messidor, DRIVE, HRF e DIA-RETDB1, cada uma com seus respectivos pré-processamentos. Como resultado, observou-se equivalência entre a localização do disco óptico em imagens originais, pré-processadas em RGB e pré-processadas em CIE Lab, que obtiveram um índice de acerto de 97.86% enquanto que as imagens com correção de iluminação radial obtiveram um índice de apenas 95.56%. Portanto, a

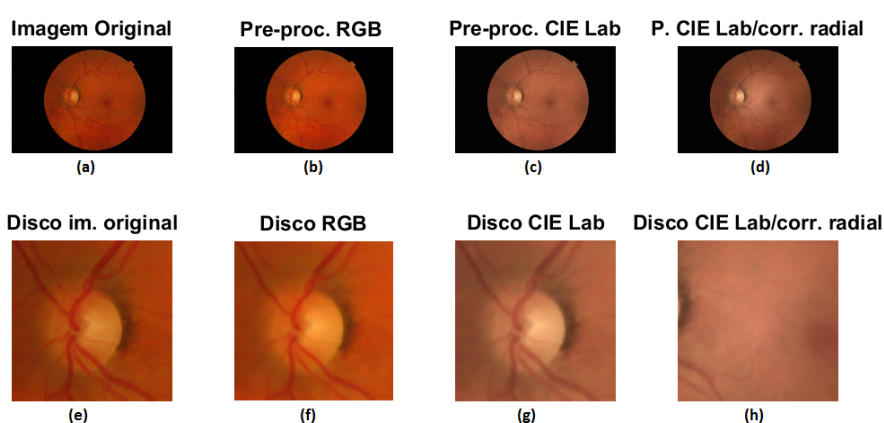
escolha do tipo de pré-processamento é determinada em razão de aspectos visuais, em que se verifica que o pré-processamento realizado no modelo RGB produz pouca alteração em relação a imagem original, enquanto que o pré-processamento CIE Lab produz grandes melhorias ao realçar o contraste e melhorar a iluminação da imagem. Assim, este é o método escolhido para as próximas etapas.

Figura 5.4: Etapas do pré-processamento das imagens em RGB




(a) Imagem original - base DRIVE, (STAAL et al., 2004). (b) Imagem após aplicação do filtro de Wiener nos canais R,G e B. (c) Imagem após ajuste de contraste. (d) Imagem após aplicação do filtro da mediana.

Figura 5.5: Teste inicial de localização do disco óptico em imagens pré-processadas



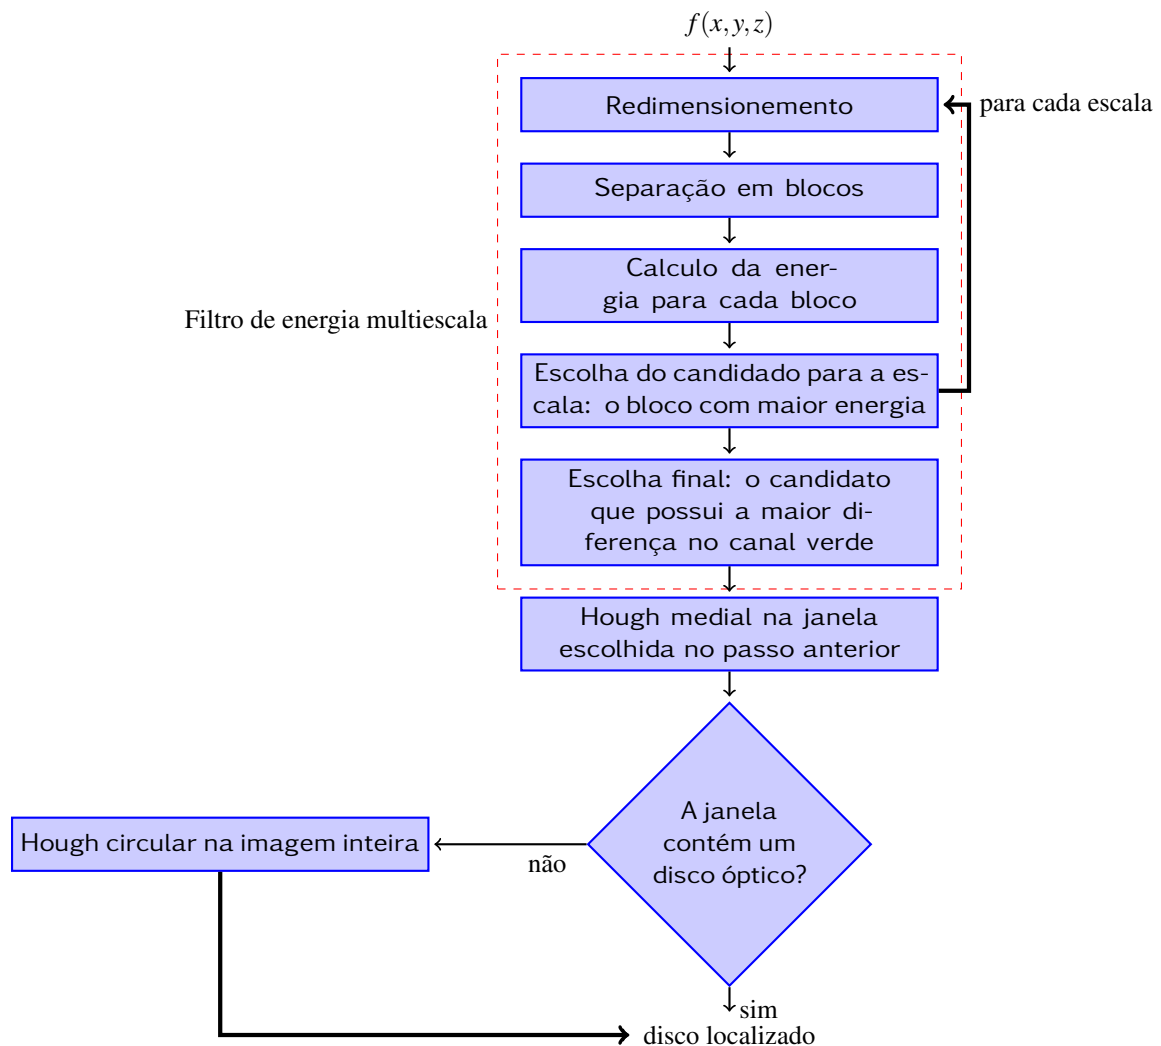
(a) Imagem original - base messidor, (DECENCIÈRE et al., 2014). (b) Imagem pré-processada em RGB. (c) Imagem pré-processada em CIE Lab. (d) Imagem pré-processada em CIE Lab com correção de iluminação radial. (e)–(h) Respectivas localizações do disco óptico.

Figura 5.6: Curva de ajuste da luminância

5.3 Localização do disco óptico

Antes de proceder com a segmentação do disco óptico é útil saber a posição deste elemento na imagem, e para isso, métodos rápidos e eficientes são empregados. No presente contexto, foram adotados dois métodos, que são: filtro de energia e transformada de Hough, o primeiro é baseado em propriedades de intensidade e o segundo é baseado na forma. Também foram feitas tentativas com superpixel, mas não foram obtidos bons resultados com esta abordagem.

A Figura 5.7 apresenta o fluxograma do algoritmo proposto para localização do disco óptico. Inicialmente a imagem é redimensionada para que apenas as características relevantes permaneçam, em seguida é obtida a energia em cada bloco da imagem. No próximo passo, o bloco com maior energia é escolhido. Esse procedimento é realizado em várias escalas diferentes resultando em vários blocos candidatos, um para cada escala. Um critério de intensidade é aplicado resultando na escolha de um bloco. Um retângulo é traçado em torno do bloco resultando em uma janela. O passo seguinte é a avaliação dessa janela por meio de transformada de Hough Medial a fim de determinar se o disco óptico está no local, caso não esteja, a imagem inteira é submetida a transformada de Hough circular, que fornece a provável posição do disco. A escolha do filtro de energia como método inicial de obtenção do disco seu deu em função da sua confiabilidade e baixo custo computacional, e ao usar a transformada de Hough como critério de decisão, tem-se um método bastante robusto que usa propriedades de cor e forma para localizar o disco óptico.

Figura 5.7: Fluxograma do algoritmo de localização do disco óptico


5.3.1 Pré-processamento para localização do disco óptico

Como observado por Suero et al. (2013) as retinografias apresentam defeitos de iluminação na extremidade da retina, a forma esférica torna a extremidade sombreada ou mais brilhante de acordo com o ângulo, foco e exposição, Figura 5.8(a). Isso ocorre também na base MESSIDOR, e por isso adicionamos uma etapa que é a aplicação de máscara para cobrir as áreas iluminadas, reduzindo a região de interesse.

A máscara é gerada dinamicamente para cada imagem: a retina é detectada por limiarização, e os pontos mais externos (esquerdo, direito, superior e inferior) são usados para projetar 8 novos pontos, 2 em cada direção. Esses novos pontos são calculados considerando o número de linhas e colunas na imagem original, sendo que os pontos acima e abaixo são projetados avançando ligeiramente para dentro da retina. A máscara final, mostrada na Figura 5.8(b), é a conexão entre todos esses pontos, com exceção dos lados esquerdo e direito, que preservam o

contorno da retina obtido na limiarização. Algumas bases de retinografia como a base DRIONS apresentam imagens centradas no disco óptico, outras como a Messidor são centradas na fóvea fazendo com que o disco fique do lado esquerdo ou direito, assim, a máscara elimina defeitos de iluminação no topo e embaixo, preservando os lados esquerdo e direito, que é onde o disco se encontra, Figura 5.8(c).

Figura 5.8: Adição de máscara para eliminar brilho intenso nas extremidades.



(a) Imagem original “20051021_51476_0100_PP.png”, Messidor (DECENCIÈRE et al., 2014). (b) Máscara para delimitar a região de interesse. (c) Junção da máscara com a imagem original.

5.3.2 Localização rápida

Quase sempre o disco óptico é a parte com maior energia, pois normalmente é mais claro que o restante da imagem. Tal característica não ocorre apenas quando há grandes exsudatos, descolamento de retina, lesões e problemas de iluminação provenientes da aquisição da imagem. Assim, optou-se pela implementação de um filtro de energia para a localização rápida do disco. O filtro foi concebido a partir da Equação de energia apresentada por Velho et al. (2009), e consiste da aplicação da referida equação aos blocos não sobrepostos da imagem:


$$g(m, n, z) = \sum_{m=i}^{i+T-1} \sum_{n=j}^{j+T-1} [f(m, n, z)]^2 \quad (5.2)$$

em que f é a imagem de entrada, $z \in \{R, G \text{ e } B\}$, $i = (1, T + 1, 2T + 1, 3T + 1, \dots, M)$ e $j = (1, T + 1, 2T + 1, 3T + 1, \dots, N)$. O tamanho do bloco é $T \times T$, M é a quantidade de blocos na horizontal, N é a quantidade de blocos na vertical, m e n são índices. A energia é calculada por blocos não sobrepostos e a imagem de saída tem um bloco por bloco de entrada. A Figura 5.9(a) mostra o resultado do filtro da energia.

O filtro foi implementado da seguinte forma. Primeiro, reduzimos as imagens pré-processadas usando quatro escalas. Em seguida, a função de energia (Equação 5.2) é calculada

em cada bloco das imagens reduzidas. Finalmente, escolhemos um bloco em cada imagem que respeita estes critérios: o valor da energia é o mais alto em toda a imagem, e a intensidade mais alta está no canal Vermelho (deve ser pelo menos 25% mais intenso que o canal Azul). Esses critérios são necessários porque blocos de alta energia com intensidades semelhantes geralmente ocorrem em exsudatos. Uma janela é traçada em torno do bloco escolhido e cada imagem reduzida fornece uma janela, Figura 5.9(b). A decisão de qual janela é a correta é baseada no critério de intensidade, pois o OD possui muitos vasos sanguíneos tornando a variação (contraste) no canal verde muito maior, (MALEK et al., 2012). Assim, para cada janela, o maior e o menor valor no canal verde são obtidos, e a janela com a maior diferença absoluta entre estes valores é escolhida. Se este critério não for adotado, áreas constantes de alta energia podem ser escolhidas erroneamente. A Figura 5.9(c) mostra a decisão sobre os candidatos a disco óptico da Figura 5.9(b).

Figura 5.9: Filtro de energia multiescala na imagem ‘23_training.tif’ da base DRIVE.



(a) Imagem depois do filtro de energia. (b) Janelas contendo os OD candidatos, cada janela é proveniente de uma escala. (c) Janela escolhida com base na variação no canal verde - no disco, os vasos sanguíneos são escuros no canal verde e o restante apresenta brilho intenso.

A Figura 5.9(a) mostra o resultado do filtro de energia, em que se observa maior ênfase no disco óptico ao passo que detalhes desaparecem, além disso, nota-se que este filtro é aplicado a pequenos blocos, o que vem a ser algo bastante comum em segmentação e análise de retinografias digitais. Em se tratando da localização do disco, Sarathi et al. (2016) utiliza uma janela de Kaiser e *hat shaped* Kaiser para determinar a região mais clara, e sugere janelas de tamanho:

$$T = \frac{1}{10}M \quad (5.3)$$

em que M é a quantidade de linhas na imagem. No presente trabalho, o tamanho destes blocos é calculado em função do tamanho da imagem reduzida, normalmente variam de 3×3 a 9×9 ,


sendo determinado pela equação:

$$T = 4 \frac{1}{100} M \quad (5.4)$$

A escolha de blocos menores se deu em função das particularidades do filtro de energia. Extensas áreas claras possuem grande energia, o que pode confundir o filtro caso blocos muito grandes sejam utilizados. Por outro lado, blocos pequenos podem reduzir o filtro a um simples localizador de pixel com intensidade máxima global, o que ocasiona erros em relação a exsudatos e defeitos de iluminação. A retinografia da Figura 5.10(a) possui grande energia e iluminação intensa nas extremidades, por isso ilustra bem a questão do tamanho do bloco: variando a Equação 5.4 é possível perceber que o bloco não deve ser pequeno demais, pois neste caso um pequeno conjunto de pixels claros influencia fortemente a decisão do filtro levando ao erro, é o caso da Figura 5.10(b) cujo bloco tem tamanho $T = 3(1/100)M$, por outro lado, blocos grandes demais tendem a eleger áreas constantes e claras como sendo o disco, é o caso da Figura 5.10(e), que utiliza o tamanho sugerido por Sarathi et al. (2016). Portanto, o tamanho ideal, não deve ser equivalente ao disco, mas sim, uma proporção do mesmo, uma boa faixa de tamanho vai de 1/4 a 1/2 da quantidade de linhas esperadas em um disco, afinal, no pior caso, ao separar a imagem em blocos, o disco será dividido em 4 partes iguais e 1/4 de disco será a porção máxima de disco em qualquer bloco. Levando em consideração que o disco ocupa cerca de 16% das linhas, o valor usado no filtro deve ser de 4% a 8% da quantidade de linhas da imagem. De fato, os melhores resultados foram observados dentro desta faixa, a Figura 5.10(c) ilustra o uso de 4%, e a Figura 5.10(d) ilustra o uso de 6%. Testes em aproximadamente 1500 imagens mostraram melhor desempenho com 4%, isso porque o disco costuma apresentar uma pequena área mais clara, que é o cálice óptico, e com a janela ou bloco menor este elemento se sobressai auxiliando a localização do disco. Vale destacar que enquanto a quantidade de linhas se mostrou altamente relevante para a determinação do tamanho do bloco, a quantidade de colunas não traz nenhuma informação útil, pois em algumas bases as laterais são preenchidas com pixels pretos elevando o número de colunas sem que haja informação útil nelas.

Uma vantagem adicional do filtro de energia é que a medida que o mesmo busca o bloco com maior energia também filtra o padrão de cores RGB presente no bloco, o que torna primordial a realização de uma análise dos canais RGB e seus respectivos histogramas, Figuras 5.11 e 5.12. Embora haja muita variação entre uma base e outra e até na mesma base, algumas características podem ser determinadas de maneira universal: normalmente, o disco possui

Figura 5.10: Imagem com grande concentração de energia e localização do disco com diferentes tamanhos de bloco.



(a) Imagem “23_training.png” da base DRIVE, (STAAL et al., 2004) contendo áreas com grande energia. (b) Disco obtido com bloco de tamanho $3(1/100)M$. (c) Disco obtido com bloco de tamanho $4(1/100)M$. (d) Disco obtido com bloco de tamanho $6(1/100)M$. (e) Disco obtido com bloco de tamanho $(1/10)M$.

maior brilho que o restante da imagem, portanto, nos três canais espera-se encontrar as maiores intensidades no disco óptico e consequentemente as maiores energias, além disso, o vermelho é brilhante para todo o fundo de olho e alcança as maiores intensidades em relação aos outros canais, o azul é bastante escuro e o verde apresenta um bom contraste. Nos histogramas também é possível perceber a tendência do vermelho em gerar maior espalhamento enquanto que o azul e o verde costumam apresentar picos bem definidos em torno dos valores de intensidade que compõem o disco. Diante de tais análises, opta-se por utilizar as energias dos canais verde e azul enquanto que o canal vermelho tem suas intensidades utilizadas como critério de decisão, isso para evitar que eventualmente áreas com vermelho muito intenso sejam confundidas com o disco, basicamente essa forma de filtrar pode ser traduzida da seguinte maneira: nem toda área com grande intensidade no vermelho é disco mas todo disco possui grande energia no verde e azul e o seu vermelho é mais intenso que ambos. Nas Figuras 5.12 e 5.11 também é possível perceber o maior contraste do canal verde no disco óptico.


Figura 5.11: Análise de cor dos discos da base Messidor

Imagem Original, canais RGB e histograma RGB.


Figura 5.12: Análise de cor dos discos da base DIARETDB1

Imagem Original, canais RGB e histograma RGB.


5.3.3 Localização precisa

Com o objetivo de melhorar o desempenho do filtro foi agregado um critério de decisão com base na forma, para isso foi escolhida a transformada de Hough circular que é o principal método desta categoria no contexto das retinografias. Levando em consideração que o disco óptico varia em tamanho, e que não é perfeitamente circular, podendo ser ovalado ou possuir bordas irregulares devido a PPA, uma implementação diferenciada da transformada de Hough foi concebida, sendo designada por Hough medial. Essa designação é decorrente do fato de que a

mesma utiliza princípios da transformada do eixo medial, MAT, cujo objetivo é obter o esqueleto da forma preenchendo-a com uma série de discos de raio máximo de maneira que os discos não ultrapassem suas fronteiras. A junção de todos os centros dos discos maximais resulta em uma linha que corresponde exatamente ao esqueleto da forma, Figura 5.13(a), (SANTOS, 2007). No caso de um círculo, o esqueleto é um ponto que corresponde a seu centro.

Enquanto a MAT ajusta o raio do círculo inscrito dentro do contorno para então encontrar o centro de uma forma, a transformada de Hough medial faz o oposto, parte dos pontos do contorno e utiliza raios predefinidos para traçar círculos em volta deles, ao final, escolhe o ponto com maior número de círculos passando por ele para ser o centro, Figura 5.13(b). Essa abordagem é interessante no problema em questão pois mesmo que o disco óptico possua grandes irregularidades a melhor posição para o centro será encontrada, as falhas ocorrem apenas em função da qualidade do contorno.

Figura 5.13: Eixo medial e Hough medial




(a) Transformada do eixo medial, **Fonte:** Santos (2007). (b) Transformada de Hough medial.

Assim, para garantir contornos de qualidade é necessário reduzir a influência dos vasos sanguíneos sobre o disco óptico, isso é obtido por morfologia matemática, a Figura 5.14 ilustra este processo: a imagem é submetida a uma transformação para escala de cinza, e depois cria-se uma imagem com 3 canais, no primeiro e no terceiro são realizadas duas dilatações com um pequeno raio, no segundo canal apenas uma dilatação é realizada, o resultado é o contorno rosado em volta do disco, Figura 5.14(c), o próximo passo é a transformação em escala de cinza e aplicação do filtro da média, Figura 5.14(d), por último é realizado um fechamento com pequeno raio, resultando na Figura 5.14(e). A Figura 5.14(f) mostra os contornos obtidos com filtro de Canny utilizando *threshold* 0,14. Caso a quantidade de pontos obtidas no filtro de Canny seja grande em relação ao total de pixels na imagem, o procedimento é realizado novamente até que seja obtido um contorno mais conciso, isso é garantido pelas sucessivas dilatações e fechamentos


que vão eliminando a influência dos vasos sanguíneos progressivamente.

Uma diferença em relação a transformada de Hough é que a transformada de Hough medial se aplica exclusivamente a círculos, enquanto que Hough possui diversas generalizações. Como parâmetros de entrada a transformada de Hough medial recebe dois valores de raio, sendo um mínimo e um máximo e um fator de sensibilidade. Como resultado é retornada a posição do centro do círculo, caso sejam encontrados pontos suficientes que possam formar um círculo de acordo com a sensibilidade requerida. A Figura 5.15 mostra as etapas da transformada Hough medial: na Figura 5.15(a) tem-se o disco obtido por meio do filtro de energia sobreposto com o contorno gerado na etapa anterior. A Figura 5.15(b) mostra a qualidade de cada ponto candidato a centro, os pontos com maior intensidade são aqueles que enquadram o maior número de pontos do contorno, sendo que o ponto com maior valor é o escolhido. A Figura 5.15(c) mostra em vermelho a circunferência traçada a partir do ponto definido como sendo o centro, utilizando o raio mínimo e o raio máximo, é possível perceber que grande parte dos pontos do contorno do disco foram incluídos na circunferência. E por fim, o centro do disco é marcado na imagem original, Figura 5.15(d).

Figura 5.14: Obtendo o contorno do disco



(a) Imagem gerada pelo filtro de energia. **(b)** Transformação para escala de cinza. **(c)** Imagem replicada nos canais RGB recebendo diferentes dilatações em cada um. **(d)** Transformação para escala de cinza e aplicação do filtro da média. **(e)** Fechamento. **(f)** Filtro de Canny com *threshold* 0,14.

Figura 5.15: Hough Medial

(a) Contorno sobreposto a imagem de entrada. (b) Intensidades dos candidatos a centro. (c) Faixa entre raio mínimo e máximo mostrando pontos do contorno que foram enquadrados pelo centro eleito por Hough Medial. (d) Marcação do centro.

5.4 Segmentação do disco óptico

Na segmentação do disco óptico é utilizado o conceito de *Rough sets* apresentado anteriormente. Conforme foi mencionado, nesta técnica são utilizadas duas aproximações, uma inferior e outra superior, sendo o histograma e histon das imagens adotados como aproximações *Lower* e *Upper*, respectivamente. A relação entre estas aproximações gera o *roughness index* que fornece *thresholds* para separar a imagem em diversas partes.

São utilizadas as formulações apresentada por Mookiah et al. (2013b), Xie et al. (2015) e Chiranjeevi e Sengupta (2012). O método de Xie et al. é adotado em virtude da dificuldade em obter picos e vales significativos utilizando o algoritmo de segmentação proposto por Mookiah et al., que possui valores fixos determinados por meio de experimentação, por exemplo, a distância entre picos deve ser de no mínimo 10 e estes são 20% acima da média. Enquanto que o método aprestado por Chiranjeevi e Sengupta é adotado devido a dificuldade de realizar a segmentação nos canais de cores separadamente, assim como é proposto por Mookiah et al.

5.4.1 Variações em *roughness index*

Diversas implementações do *roughness index* são apresentadas. Para simplificar as legendas dos gráficos, foi adotado uma terminologia semelhantes à apresentada por Chiranjeevi e Sengupta (2012):


- ***d1*** - distância euclidiana em imagens coloridas, equações 3.15 e 3.16;
- ***d2*** - distância euclidiana em imagens A-IFS, equações 3.15 e 3.32;
- ***hist*** - histograma, Equação 3.14;
- ***Histon*** - histon, Equação 3.18;
- ***Fhist*** - *Fuzzy histogram*, Equação 3.33;
- ***FHiston*** - *Fuzzy Histon*, Equação 3.30
- ***HRI*** - *Histon Roughness Index*, Equação 3.24;
- ***FHRI*** - *Fuzzy Histon Roughness Index*, Equação 3.34;
- ***Shist*** - *Smoothed HISTogram*, Equação 4.11;
- ***SHiston*** - *Smoothed HISTON*, Equação 4.11;
- ***SFhist*** - *Smoothed Fuzzy HISTogram*, Equações 3.33 e 4.11;
- ***SFHiston*** - *Smoothed Fuzzy HISTON*, Equações 3.30 e 4.11;
- ***SHRI*** - *Smoothed Histon Roughness Index*, Equação 4.13;
- ***SFHRI*** - *Smoothed Fuzzy Histon Roughness Index*, Equação 4.13;
- ***3DMHRI*** - *3D Morphologic Histon Roughness Index*, equações 3.24, 4.14 e 4.15.;
- ***3DMFHRI*** - *3D Morphologic Fuzzy Histon Roughness Index*, equações 3.24, 3.25, 4.14 e 4.15.

5.4.2 Matriz distância

A matriz distância promove a principal vantagem da segmentação por *roughness index* em relação a segmentação por histograma, ela transporta informações espaciais da imagem para o histon. Comparando as duas formas de distância apresentadas, $d1$ e $d2$, Figura 5.16, é possível notar que a distância RGB ignora elementos menos acentuados enquanto a distância A-IFS, 5.16(b), realça até mesmo os menores detalhes. Tal resultado reflete a indecisão em classificar os pontos e isso não necessariamente é uma característica ruim: ao quantificar o grau de certeza de um ponto estar na transição entre duas áreas, surgem pontos com alto grau de certeza. É possível observar alguns pontos com grande intensidade da borda do disco na Figura 5.16(b), tais pontos são fundamentais nas etapas seguintes.

O cálculo da matriz distância representa um dos maiores gargalos na segmentação por *roughness index*, é necessário percorrer toda a imagem calculando a distância euclidiana entre um pixel e seus vizinhos, conforme as equações 3.15 e 3.16. O custo desta operação é diminuído por meio da localização prévia do disco, que reduz significativamente a região de interesse. Dessa forma, a matriz de distância é calculada apenas em uma pequena janela contendo o disco.

Figura 5.16: Diferença entre distância RGB e distância A-IFS



(a) Representação gráfica das distâncias calculadas na vizinhança por meio de distância euclidiana RGB - $d1$. (b) Representação gráfica das distâncias calculadas na vizinhança por meio de distância euclidiana A-IFS - $d2$.

5.4.3 Histogramas, histons e *roughness index*

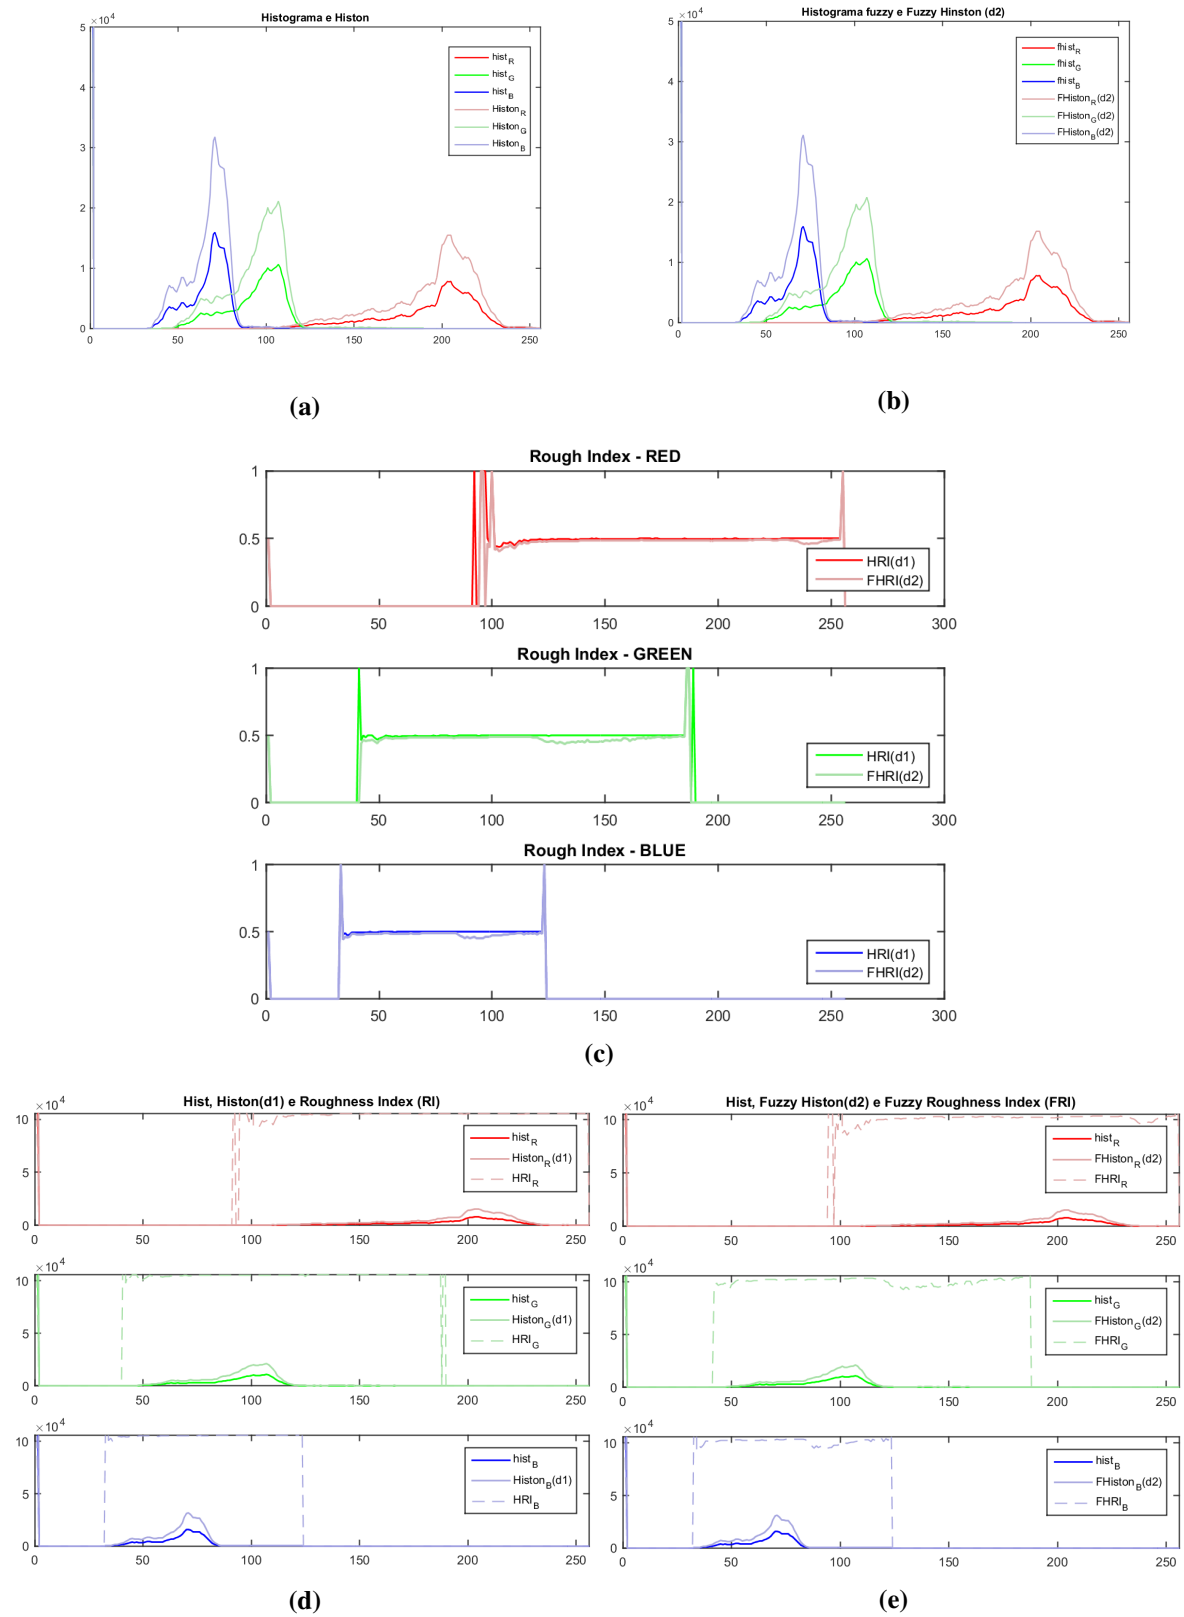
A Figura 5.17 mostra uma imagem da base HRF, e o disco localizado por meio dos métodos discutidos anteriormente. A Figura 5.18 mostra seus respectivos histogramas, histons e *roughness index* obtidos com e sem o uso de representação A-IFS da imagem. É interessante observar que o **HRI** e o **FHRI** possuem grande semelhança (Figura 5.18(c)), notando-se ligeiras perturbações no **FHRI**, tais perturbações resultam em vales mais precisos que os do **HRI**, conforme pode ser observado na Figura 5.19. Um possível questionamento quanto a vales com pouca expressividade seria a geração de regiões muito pequenas, embutidas em regiões maiores, isso não ocorre pois as pequenas perturbações que geram vales são avaliadas quanto a sua expressividade em termos de área pelo algoritmo de *merging*, a sugestão de Mushrif e Ray (2008) é que regiões menores que 0,1% sejam fundidas, no entanto, este valor precisa ser avaliado particularmente para cada situação.

Figura 5.17: Imagem original a ser segmentada

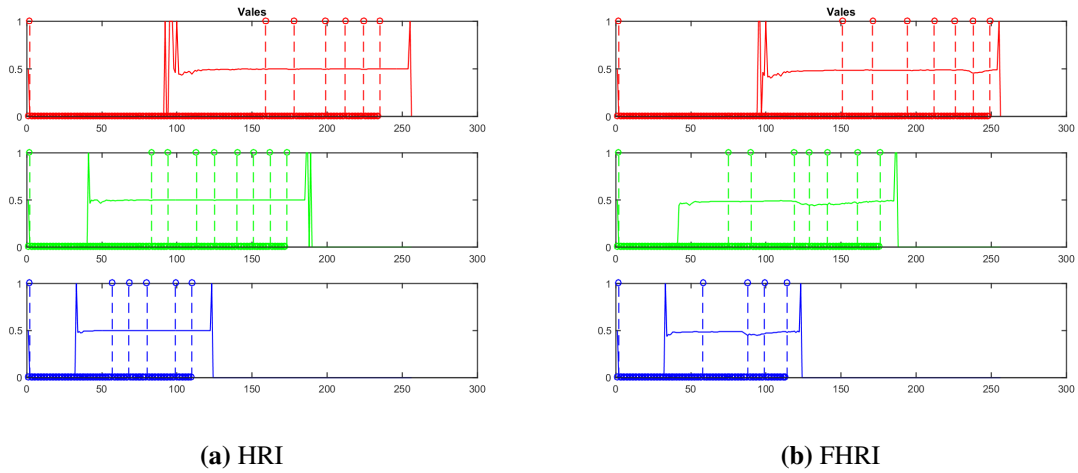
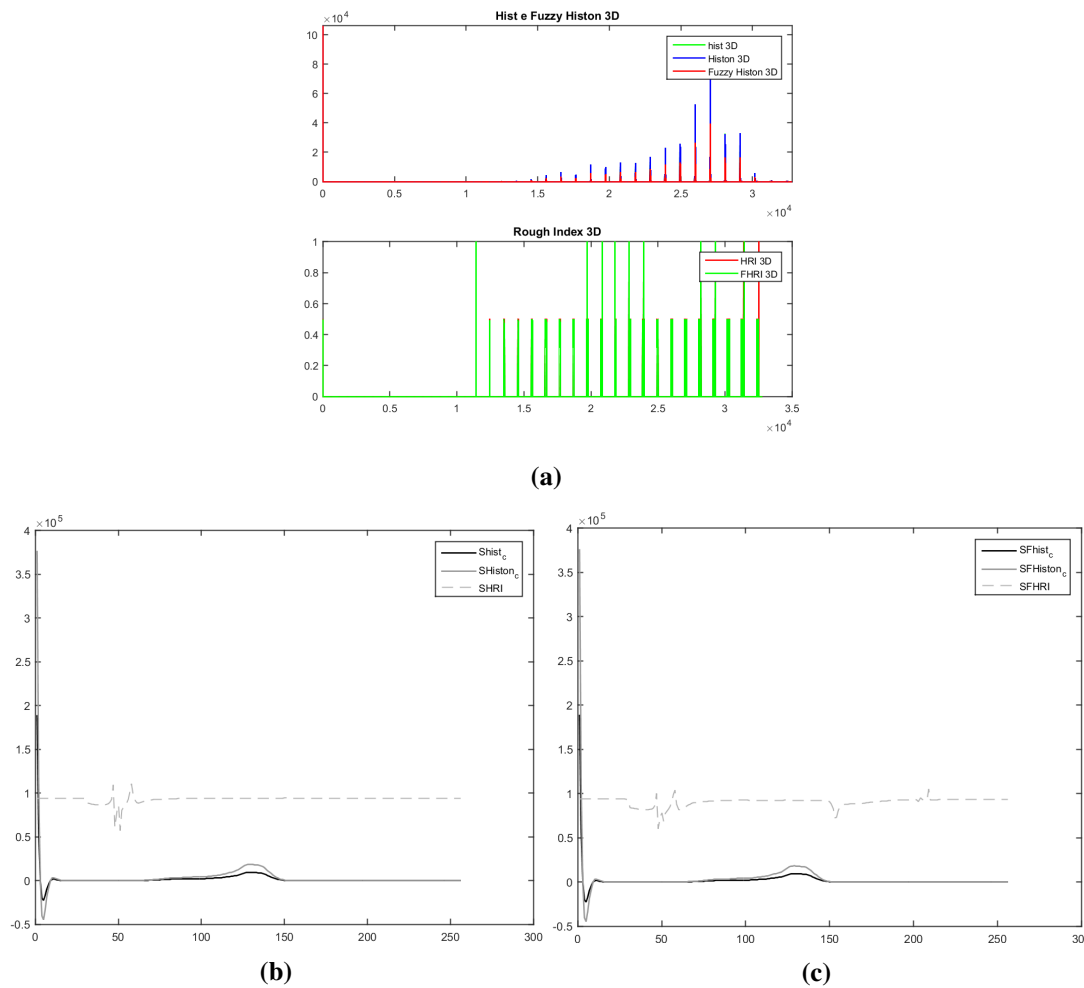


(a) Imagem original, base HRF, (BUDAI et al., 2013b). (b) Disco óptico localizado.

Além do **HRI** e do **FHRI** também são exibidos o **SHRI** e o **SFHRI** (Figura 5.20(b)-(c)) que implicam na transformação da imagem para escala de cinza. É possível notar que o **SHRI** e o **SFHRI** geram *roughness index* bastante compactos e portanto uma segmentação com uma quantidade menor de regiões.

Figura 5.18: Histogramas, Histons e *Roughness Index*: básico e A-IFS

(a) Histograma e Histon básico. (b) Histograma e Histon A-IFS. (c) *Roughness index* básico e A-IFS nos canais RGB. (d) Sobreposição do Histograma, Histon e *roughness index* básico. (e) Sobreposição do Histograma, Histon e *roughness index* A-IFS.

Figura 5.19: Vales seleccionados por meio do *roughness index***(a)** Vales gerados pelo **HRI**. **(b)** Vales gerados pelo **FHRI**.**Figura 5.20:** Histograma, histons e *roughness index*: 3D e *smoothed***(a)** Histograma, Histon e A-IFS Histon na parte superior e *roughness index* 3D (básico e A-IFS) na parte inferior. **(b)** *Smoothed* histograma, histon e *roughness index* básicos. **(c)** *Smoothed* histograma, histon e *roughness index* A-IFS.

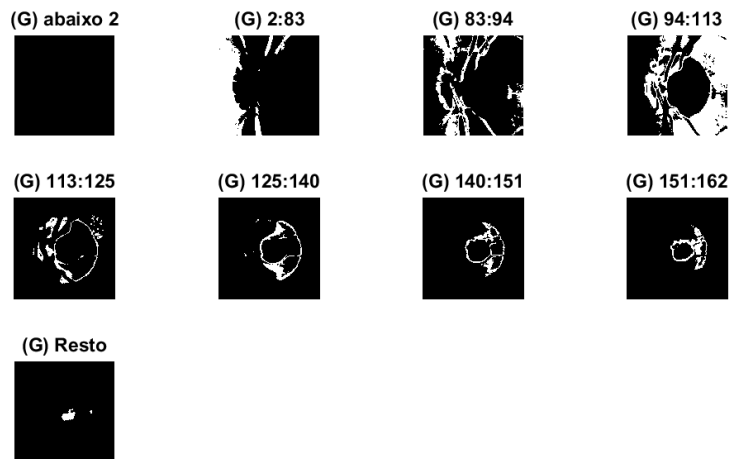
5.4.4 Segmentação por meio do *roughness index* clássico

Após a obtenção dos vales, os mesmos são utilizados como *thresholds* em um processo de limiarização, cada dois vales geram uma região, sendo que cada canal de cor possui seu próprio conjunto de *thresholds* e o resultado final da segmentação é a interseção de todas as regiões obtidas. A Figura 5.21 ilustra o processo de limiarização por meio de **HRI**, em que para cada canal, os *thresholds* são tomados 2 a 2 e a região gerada por eles é plotada. Em alguns intervalos nota-se boa segmentação de partes do disco e em outros boa segmentação dos vasos sanguíneos, enquanto que alguns não trazem informações perceptíveis ou úteis. No entanto, é possível constatar que não há uma maneira óbvia de fazer o merge das regiões de forma a obter apenas o disco óptico, os vasos sanguíneos sobrepostos ao disco se misturam e se fundem completamente ao lado nasal, criando um grande dificultador para o método. Assim, torna-se preponderante o uso de alguma técnica de remoção dos vasos sanguíneos para que o merge possa efetivamente resultar no disco óptico.


A Figura 5.22 mostra uma imagem segmentada utilizando os quatro *roughness index* discutidos, em que se observa um número maior de pequenas regiões na segmentação por **HRI** em comparação com **FHRI**, se por um lado isso favorece o resultado final da segmentação do **FHRI**, por outro, pode gerar a fusão de regiões distintas, isso ocorre no lado nasal do disco óptico, área em que há grande presença de vasos sanguíneos, Figura 5.22(b), em função disso partes do disco se unem aos vasos, tornando-se indistinguíveis. Já a segmentação por **SHRI** e **SFHRI**, mostra uma quantidade de regiões ainda menor.

Figura 5.21: Limiarização com base nos *thresholds* do *rough index* básico - HRI

(a)




(b)



(c)

(a) Limiarização no canal *red*. (b) Limiarização no canal *blue*. (c) Limiarização no canal *blue*.

Figura 5.22: Resultados da segmentação por *roughness index*

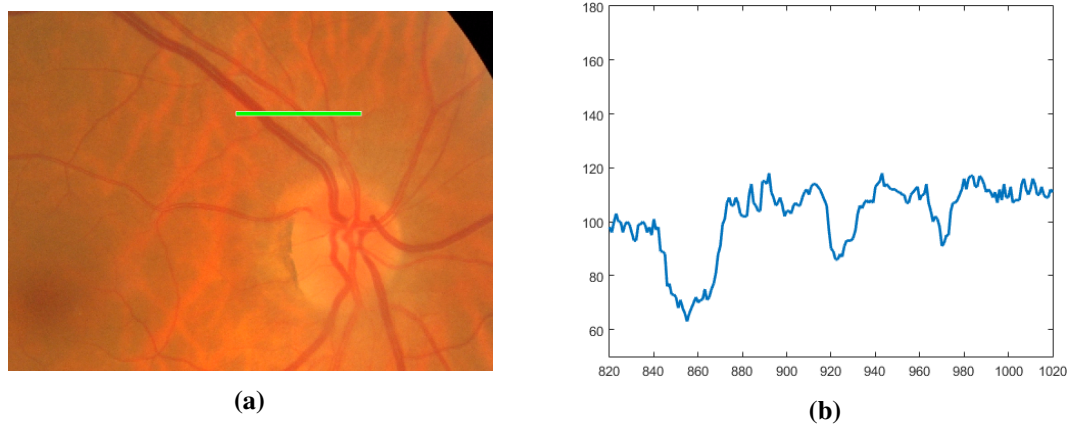
(a) Segmentação por *roughness index* básico **HRI**. (b) Segmentação por *roughness index* A-IFS **FHRI**. (c) Segmentação por *smoothed roughness index* usando LPR, **SHRI**. (d) Segmentação por *smoothed roughness index* A-IFS **SFHRI** usando LPR.

5.4.5 3D Morphologic Fuzzy Histon Roughness Index (3DMFHRI)

Roughness index clássico não produz bons resultados em função dos vasos sanguíneos, assim, é preciso criar uma estratégia para eliminar tais elementos do disco óptico. Ao mesmo tempo, deve-se garantir que a estratégia possua baixo custo computacional para que não anule uma das principais características de método que é a rapidez.

Uma das alternativas mais comum para obter vasos é o *matched filter*, em que um kernel Gaussiano é aplicado em toda a imagem na tentativa de aproximar o perfil do corte do vaso sanguíneo, que se assemelha a uma curva Gaussiana, Figura 5.23, (CHAUDHURI et al., 1989). Outras aproximações (curvas) tem sido testadas e mostram bons resultados, (SARATHI et al., 2016). No entanto, a dificuldade com o uso de *matched filter* na segmentação do disco óptico é a necessidade de fazer o *inpainting* dos vasos sanguíneos após a sua detecção.

Com base nesses fatos, optamos pela morfologia usando um elemento estruturante não plano (unflat ball), Figura 5.24(a), em vez de tentar detectar os vasos sanguíneos com *matched*


Figura 5.23: Secção transversal em uma imagem englobando três vasos sanguíneos.

(a) Corte transversal em imagem de fundo de olho (linha verde). (b) Representação das intensidades da linha de corte: os vasos sanguíneos são mais escuros e geram uma curva aproximadamente gaussiana.

filter. O elemento estruturante adotado possui todas as variações desejadas para localizar os vasos sanguíneos, pode detectar vasos de qualquer tamanho ou orientação e com a vantagem de que a operação morfológica detecta e remove o padrão correspondente de uma só vez. O resultado da operação (dilatação com unflat ball de raio 0,3% da quantidade de linhas) é uma imagem sem vasos sanguíneos, mas com alguns artefatos: pequenas bolas surgem ao longo da imagem, Figura 5.24(c). Isso poderia ser um problema para as etapas seguintes, mas observa-se que uma segmentação suave contorna o problema e mantém a forma do disco óptico.

Neste contexto, uma segmentação suave é realizada com a subdivisão da imagem por meio 3D Morphologic Fuzzy Histon Roughness Index (3DMFHRI) adotando um tamanho pequeno para as regiões. Caso contrário, os artefatos de fora do disco óptico podem ser fundidos com o disco, a imagem segmentada é mostrada na Figura 5.24(d). Após a segmentação, o disco óptico é isolado usando informações de cor e tamanho, Figura 5.24(e). As pequenas regiões guiam o processo de isolar o disco.

A etapa de isolar é realizada com base no tamanho do disco assim como em Mookiah et al. (2013a). Primeiro, foi estimada uma porcentagem média que o disco óptico ocupa na janela que vem da etapa de localização, para o qual encontramos o valor 33% (adotamos o valor 30% para assegurar que discos pequenos possam ser convenientemente segmentados uma vez que a próxima fase compensa pequenas falhas). Em seguida, a região (cluster) mais escura é removida e o tamanho restante do disco é verificado. Esse processo é repetido várias vezes e termina quando o disco encontrado se torna menor que o tamanho médio. A maneira como as regiões são organizadas e o valor adotado como tamanho médio permite que as remoções sejam feitas

Figura 5.24: Segmentação por 3DMFHRI

(a) Elemento estruturante não-plano. (b) Imagem original. (c) Imagem depois da dilatação. (d) Segmentação suave com 3DMFHRI. (e) Disco isolado após erosão. (f) Regularização do disco por meio de uma elipse. (g) Sobreposição entre o disco detectado e a imagem original. (h) Ampliação do resultado: disco detectado (verde), *groundtruth* determinado pelo especialista (azul), acc: 99,95.

além do tamanho real do disco, no pior cenário apenas o lado temporal do disco é inteiramente preservado e apenas pequenas partes do lado nasal aparecem no resultado.

Algumas correções são realizadas em seguida: o centro do disco (resultante da etapa de localização) é usado para remover os excessos que possam haver ao redor do disco, e erosão é usada para compensar as dilatações na etapa de pré-processamento. O resultado do isolamento é um disco com bordas irregulares, Figura 5.24(e). Para resolver isso, uma elipse é desenhada usando a informação da área delimitada: centróide, área, o comprimento do eixo principal, comprimento do eixo menor e orientação, Figura 5.24(f). Este procedimento gera um bom resultado porque em geral o lado temporal do disco é bem identificado pelo método, o lado nasal pode resultar em partes faltantes devido à vascularização, isto é compensado pela elipse. A Figura 5.24(g) mostra a sobreposição entre a área detectada e o OD na imagem original. A Figura 5.24(h) mostra o detalhe do contorno detectado em comparação com o contorno demarcado por um especialista, este último é quase completamente coberto pelo contorno encontrado pelo método proposto, resultando em uma acc de 99,95%.

O algoritmo de segmentação proposto (Algoritmo 4) é baseado na representação unidi-

mensional do histograma 3D e do histon 3D, e consequentemente do *roughness index*, Figura 5.25. Em imagens de baixo contraste como retinografias, não há mudanças abruptas nos níveis de intensidade resultando em baixa separabilidade e ao mesmo tempo há uma forte correlação nos canais R, G e B no espaço de cor dos objetos na imagem. Ao definir um tamanho adequado para a região a ser encontrada, podemos obter objetos utilizando os vales do *roughness index* 3D, afinal, cada bin de histograma/histon é tratado como uma cor em um espaço 3D representando o modelo de cores RGB. Em uma abordagem tradicional cada canal é avaliado separadamente durante a etapa de divisão em regiões, ignorando a correlação das cores dentro do espaço do objeto. O algoritmo de segmentação é simples e rápido e não requer cálculos complexos em um espaço 3D. No Algoritmo 4, inicialmente o 3DMFHRI é calculado e seus picos obtidos, os vales são determinados a partir dos picos. A etapa seguinte é separar a imagem em regiões com base nos vales (*thresholds*): a região entre dois vales é separada do restante e se seu tamanho estiver abaixo do mínimo a região será agregada com o resultado da próxima limiarização, caso o tamanho seja suficiente a região é inserida na imagem de saída. A cor da nova região é média de cor dos seus pixels.


Algoritmo 4: Segmentação por 3DMFHRI

```


input : tamanho mínimo de uma região minSize e imagem I
output : imagem segmentada S

1 begin
2   h ← calcula3DMFHRI(I);
3   p ← encontraPicos(h);
4   v ← encontraVales(p,h);
5   regiao ← ∅;
6   S ← ∅;
7   /* Em seguida as regiões devem ser separadas conforme os
      vales encontrados. */
8   foreach vale vi em v do
9     temp ← limiariza(I,vi,vi+1); /* temp é região entre vi e vi+1 */
10    regiao ← regiao + temp;
11    if tamanho(regiao) > minSize then
12      S ← S + media(regiao); /* média das cores na região */
13      regiao ← ∅;
14    end
15    /* caso o tamanho seja menor, a região em temp fara
      merging com a próxima região encontrada */
16  end

```

Figura 5.25: Histograma 3D e Histon 3D

(a)



(b)

(a) Duas perspectivas de um histograma 3D, pontos escuros são cores RGB com maior frequência. (b) Histograma 3D, Histon 3D e Fuzzy Histon 3D projetados em uma dimensão.

5.5 Segmentação dos vasos sanguíneos

A segmentação dos vasos sanguíneos é uma tarefa de grande importância para o diagnóstico e monitoramento de retinopatia diabética, retinopatia hipertensiva, dentre outros. Diversos caminhos podem ser seguidos para realizar a segmentação deste elemento e é bastante comum encontrar métodos supervisionados na literatura (ZHANG et al., 2015).

Neste trabalho, propõe-se uma rede neural multicamadas que combina o algoritmo de retro-propagação com técnicas de pré-processamento de imagem e pós-processamento para segmentar a estrutura vascular da retina. A rede implementada não possui características inovadoras, no entanto, observa-se nos experimentos que não é óbvio acertar boas estratégias de pré e/ou pós-processamento e que o impacto dos mesmos pode até fazer com que uma rede simples como a utilizada supere redes mais sofisticadas como CNN.

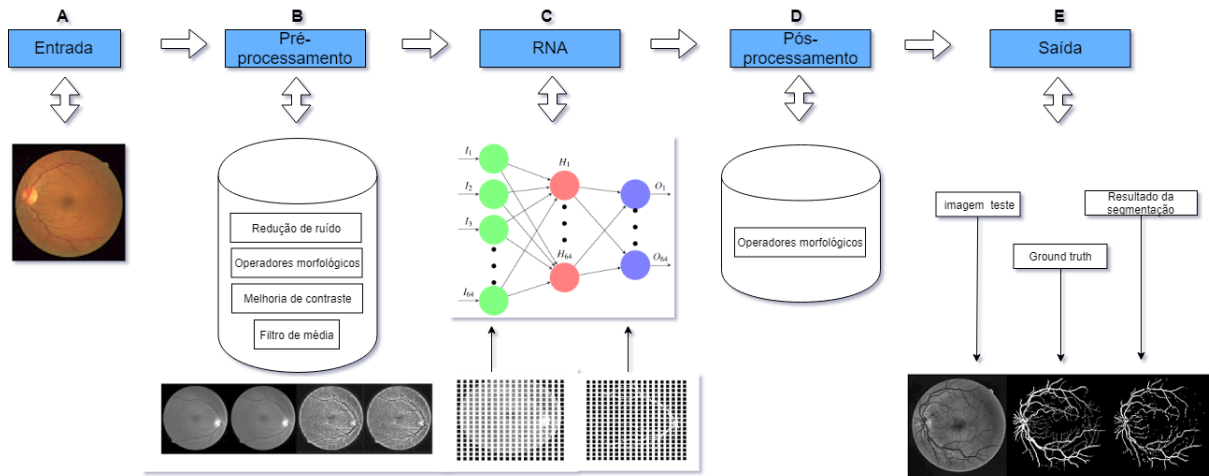
A rede foi treinada com o conjunto de treinamento da base DRIVE, e com as imagens segmentadas por especialistas (*ground truth* da base DRIVE), que guiam o processo de aprendizagem. Após o treinamento o método é usado para segmentar outras imagens (conjunto de teste) em um processo que classifica os pixels como vasos ou não-vasos. A qualidade da segmentação é avaliada em termos da classificação manual realizada por um especialista, conforme discutido anteriormente.

O diagrama de blocos da Figura 5.26 mostra uma visão geral da metodologia proposta para a segmentação de vasos sanguíneos. Na aquisição, estágio **A**, as imagens foram obtidas da base DRIVE. A especificação desta base foi discutida no capítulo 3. Enquanto que na saída, estágio **E**, a imagem é rearranjada e exibida ao lado da imagem original e do *ground truth*. O rearranjo é necessário pois durante o pré-processamento ocorre a divisão da imagem em vários blocos. Os outros estágios são descritos a seguir.

5.5.1 Estágio B - pré-processamento

A etapa de pré-processamento representada no **estágio B** da Figura 5.26 é dividida em quatro sub etapas: redução de ruído, operações morfológicas, melhoramento de contraste e filtragem com filtro da média.

Antes de iniciar estas etapas é conveniente reduzir a quantidade de informação, e para isso utiliza-se conhecimento inerente ao problema. A imagem colorida é separada em canais RGB e apenas o canal verde é usado pois é o canal com os vasos sanguíneos mais evidentes (discutido anteriormente).

Figura 5.26: Diagrama da metodologia proposta para segmentar vasos sanguíneos.

Em seguida, o filtro de Wiener é aplicado com o objetivo de minimizar a influência do ruído no processo de treinamento. Geralmente as retinografias apresentam algum nível ruído gaussiano, assim, uma redução de ruído deve ser realizada, porém, de forma suave para evitar a perda de vasos sanguíneos finos. A filtragem de Wiener utiliza uma janela de tamanho 2×2 que percorre a imagem completamente obtendo estimativas de média e variância para cada pixel. Quando a variância é grande, o filtro realiza pouca suavização; quando a variância é pequena, a suavização é mais forte. Áreas de grande variância contém transição ou bordas e suavizá-las pode incorrer em perda de informação, enquanto que áreas constantes (variância pequena) tendem a exibir o ruído com maior evidência e por isso podem receber uma suavização mais agressiva. O valor da potência do ruído branco gaussiano a ser removido foi fixado em 0,015.


Para eliminar pequenos artefatos relacionados à aquisição ou à pigmentação no fundo do olho, foi aplicada morfologia matemática. Um elemento estruturante quadrado 2×2 percorre toda imagem realizando uma operação morfológica de abertura: uma erosão afina algumas partes e desaparece com pequenos pontos claros isolados e uma dilatação que retorna as estruturas erodidas ao seu estado pré-erosão mas sem retornar os pontos isolados.

O contraste dos vasos sanguíneos é melhorado com a aplicação de *Contrast Limited Adaptive Histogram Equalization* (CLAHE). A imagem é dividida em pequenos blocos, chamados *tiles*, o melhoramento do contraste é executado em cada um deles individualmente. Várias configurações possíveis podem ser usadas com o CLAHE, foram utilizados 31×31 *tiles*, que foram combinados com seus vizinhos por interpolação bilinear. O formato do histograma de cada bloco resulta em uma distribuição, para isso foi adotada a distribuição uniforme. O limite de aumento de contraste foi fixado em 0,03. Detalhes sobre o uso de CLAHE podem ser encontrados

no trabalho de Pizer et al. (1987) e Ma et al. (2017).

Por fim, foi aplicado o filtro de média para suavizar os efeitos do pré-processamento anterior; por exemplo, a junção de peças pode produzir limites artificiais mesmo com a interpolação bilinear. Um tamanho de janela de 3×3 é usado para homogeneizar esses efeitos e os detalhes da textura. Na Figura 5.27, imagens do DRIVE são submetidas aos procedimentos acima.

Figura 5.27: Pré-processamento para segmentação dos vasos sanguíneos



(a) Canal verde da imagem original. (b) Imagem após a filtragem e filtro de Wiener. (c) Imagem após o CLAHE. (d) Imagem após filtro da média.

O pré-processamento descrito só foi obtido após inúmeros testes e ajustes. Observa-se que mesmo as menores alterações geram resultados muito distintos.

5.5.2 Estágio C - treinamento da RNA

O estágio C da Figura 5.26 é o treinamento por meio de redes neurais. Para prover melhorias a esta etapa, adotou-se uma estratégia muito utilizada quando se tem poucos dados para alimentar a rede: o conjunto de treinamento foi aumentado adicionando as imagens originais modificadas. As imagens são giradas em 180° e inseridas no conjunto de treinamento, totalizando 40 imagens: 20 imagens originais e 20 resultantes da transformação. Cada imagem é dividida em blocos de tamanho 8×8 , resultando em 5183 blocos, e um conjunto de treinamento com 207.320 amostras. Os blocos de imagem são vetorizados e cada pixel no bloco vetorizado é uma entrada de neurônio. A imagem do *ground truth* também é separada em blocos, da mesma forma que a imagem de entrada.

A rede emprega o algoritmo de inicialização de Nguyen-Widrow, (FAUSETT, 1994), e usa o algoritmo de retropropagação com os seguintes parâmetros: 64 neurônios na camada de entrada, 128 neurônios na camada oculta e camada de saída com 64 neurônios. Esse método opera em duas etapas: *forward*, em que cada bloco é apresentado à camada de entrada da rede, e

o resultado flui através da rede, camada por camada, até que uma resposta seja produzida pela camada de saída; *backward*, em que a saída obtida é comparada com a saída desejada para o bloco de entrada, o erro de classificação é calculado e propagado da camada de saída para a camada de entrada. Dessa forma, os pesos sinápticos são alterados entre duas interações com relação ao erro de *back-propagation*. A estratégia para minimizar o erro na classificação de pixels é um gradiente descendente com um termo de momentum. A atualização das matrizes com o termo momentum é expressa pela Equação 5.5:

$$W_{ji}^L(t+1) = W_{ji}^L(t) + \alpha(W_{ij}^L(t) - W_{ij}^L(t-1)) + \eta \delta_j^L Y_j^{L-1} \quad (5.5)$$

onde η é a taxa de aprendizado do algoritmo de *back-propagation* e α é a taxa de momentum. $W_{ij}^L(t)$ são os pesos da camada L no tempo t, e $W_{ij}^L(t-1)$ são os pesos da camada L no tempo t-1, este termo reflete o quanto as matrizes sinápticas mudaram entre uma interação e outra. A matriz de peso W_{ji} deve ser ajustada na direção oposta do gradiente para minimizar o erro. Portanto, a Equação 5.5 atualiza os pesos dos neurônios nas camadas envolvidas, considerando a diferença entre as respostas produzidas por suas saídas em relação aos seus respectivos valores desejados.

A rede foi treinada em várias rodadas nas quais eram promovidas mudanças nos parâmetros da rede e no pré-processamento das imagens de entrada. Uma hierarquia foi estabelecida para as mudanças: pré-processamento, número de Neurônios na Camada Oculta (NCO), número de neurônios na camada de entrada/saída (ambos correspondem ao tamanho do bloco), α e η , estes últimos são os parâmetros diretamente ligados ao aprendizado da rede.

Todos os parâmetros foram definidos aleatoriamente a princípio. A cada nova rodada, uma mudança era realizada: apenas o parâmetro imediatamente abaixo (na hierarquia) daquele que havia sido modificado na rodada anterior podia ser modificado. Assim, as variações no pré processamento levaram a uma ampla gama de testes, observando-se que pequenas variações afetam os resultados significativamente. Foram testadas diversas possibilidades relacionadas ao tamanho dos filtros, número de *tiles* no CLAHE, potência do ruído no filtro de Wiener, elementos estruturantes nas operações morfológicas, etc.

Ao final de todos os ciclos de treinamento os parâmetros ideais foram definidos em: NCO como 128, tamanho de bloco 8×8 (64 neurônios na camada de entrada/saída), α como 0,000282 e η definido como 0,009125; definiu-se o número de épocas em 300 pois não há ganhos significativos ao aumentar este número. Observa-se que ao mudar o número de neurônios na camada de entrada, os parâmetros α e η precisam ser ajustados novamente. Os parâmetros

definidos para o pré-processamento foram discutidos anteriormente.

5.5.3 Estágio D - pós-processamento

No pós-processamento, foi utilizada a operação de abertura morfológica para minimizar os pontos isolados. Adotou-se um elemento estruturante em forma de cruz 3×3 que elimina os pontos isolados na erosão e devolve os vasos detectados ao seu estado original na dilatação.

Também foi usada uma operação de pesquisa para conectar os vasos sanguíneos com interrupções curtas. Uma matriz de conexões possíveis em uma vizinhança é submetida a um processo de pesquisa que substitui o padrão encontrado por uma ligação entre os pixels em questão. A matriz utilizada enfatiza a necessidade de construir pequenas pontes entre os pixels da imagem binária resultantes da classificação em vasos e não-vasos realizada pela rede.

5.6 Considerações finais deste capítulo

Este capítulo apresentou o método proposto neste trabalho levando em consideração a ordem em que são realizadas as tarefas de segmentação. A aquisição consiste da obtenção de bases públicas, o pré-processamento consiste em operações como o filtro de Wiener e filtro da mediana no canal de luminância. A segmentação foi realizada por partes: inicialmente a localização do disco óptico seguida de sua segmentação e por fim a segmentação dos vasos sanguíneos.

Quanto a base de conhecimentos necessária para a segmentação de imagens de fundo de olho tem se os conceitos apresentados no capítulo 2. As informações mais relevantes são o tamanho dos elementos fisiológicos, a localização e distância desses elementos em relação a outras estruturas, cores etc.

A grande dificuldade em utilizar métodos baseados em contornos na localização ou segmentação do disco óptico é o baixo contraste em relação ao fundo o que gera bordas fracas e quase sempre indetectáveis por métodos de derivada de primeira e segunda ordem tais como Sobel, Laplaciano, Roberts etc. Por outro lado, alterar a sensibilidade desses métodos pode fazer com que eles detectem uma infinidade de detalhes provenientes de veias e outros artefatos, é o caso do filtro de Canny usado neste trabalho em conjunto com a transformada de Hough. Com isso, para obter o funcionamento razoável deste método no presente contexto, foi necessário um forte processamento a fim de remover vasos sanguíneos ao passo que o disco é mantido. É comum o uso de morfologia matemática em imagens de fundo de olho, assim, neste trabalho

optou-se por remover os detalhes em torno do disco com fechamento e dilatação: a dilatação promove o desaparecimento dos vasos sanguíneos ao expandir as partes claras enquanto que o fechamento melhora o contorno do disco fundindo quebras e eliminando pequenos buracos e fendas ocasionados pelos vasos sanguíneos.

Complementando o método de localização proposto, inicialmente utiliza-se o filtro de energia multiescala como estimativa inicial do disco e a transformada de Hough medial é responsável por informar se de fato o fragmento de imagem contém um disco. A transformada de Hough implementada se baseia na transformada do eixo medial e foi concebida desta forma para comportar as irregularidades no contorno do disco.

Quanto a segmentação do disco óptico, foi proposto um novo método baseado em *roughness index* 3D que é agregado a morfologia matemática para eliminar a influência dos vasos sanguíneos, sem a necessidade de *inpainting* dos vasos, uma vez que tal técnica pode apresentar alto custo computacional eliminando as principais vantagens de se utilizar métodos baseados em limiarização, que é simplicidade e o baixo custo. O algoritmo de segmentação baseado no *roughness index* 3D acomoda os efeitos das operações morfológicas resultando em uma segmentação eficiente, que gera uma forte correlação das cores no espaço do objeto.

A segmentação dos vasos sanguíneos foi resolvida por meio de redes neurais artificiais *multilayer perceptron* sendo que o pré-processamento realizado constitui um grande diferencial que proporciona grandes melhorias ao método.

O próximo capítulo apresenta os resultados obtidos de acordo com as métricas adotadas.

CAPÍTULO 6

RESULTADOS

Este capítulo apresenta os resultados obtidos a partir dos métodos descritos no capítulo anterior. As imagens foram processados com MatLab em um computador com Windows 10 de 64 bits (CPU Intel(R) Core™ i7-8750H @2,20 GHz, 6 core(s), 16 GB de RAM). Foram definidos experimentos de localização, segmentação do disco óptico e segmentação dos vasos sanguíneos, que serão aprestados a seguir.

6.1 Resultados em localização do disco óptico

A localização do disco óptico foi realizada em duas etapas: a primeira é a localização rápida usando filtro de energia multiescala e segunda é o uso de transformada de Hough medial como critério de decisão para definir se o disco foi encontrado na janela retornada pelo filtro de energia. Para a primeira etapa o acerto foi definido como sendo a capacidade do método em incluir pelo menos 60% do disco. Para a segunda etapa foi adotado o critério 1R, em que marca-se o centro do disco e qualquer local dentro do raio do disco óptico é considerado um acerto. Outros critérios menos flexíveis são 1/2R, 1/4R and 1/8R. O raio R é definido de acordo com o raio do disco na base escolhida, usualmente, é feita uma média entre todos os discos ópticos da base (MARIN et al., 2015).

As bases DIARETDB1, DRIVE, HRF e Messidor foram avaliadas, totalizando 1374 imagens. Os valores de R adotados para o critério 1R foram obtidos de Al-Bander et al. (2018). A Tabela 6.1 quantifica os resultados, o primeiro método consiste do filtro de energia, o segundo é a transformada de Hough circular clássica na imagem inteira, o terceiro método é a transformada de Hough, conforme proposto por Abdullah et al. (2016) e o quarto é o método

híbrido proposto, baseado em energia e transformada de Hough Medial como critério de decisão. O método proposto por Abdullah et al. é a aplicação da transformada de Hough em imagens pré-processadas e com algumas adaptações, conforme discutido no capítulo 4.

Como é possível constatar, dentre os métodos avaliados, o filtro de energia com transformada de Hough consegue o melhor desempenho na localização do disco óptico, alcançando 100% nas bases DRIVE e HRF, 98.5% na base Messidor e 94,38% na base DIARETDB1. Observa-se que o método híbrido não conseguiu melhorias em relação a base DIARETDB1 pois ele depende da qualidade dos contornos gerados, e esta base não proporciona bons contornos devido aos problemas de iluminação.

É importante ressaltar que as imagens foram redimensionadas na entrada do programa fornecido por Abdullah et al. de forma a contemplar os diferentes tamanhos de imagens das bases testadas. Assim, o raio foi mantido fixo, conforme definido por Abdullah et al., enquanto a imagem se adequava ao raio esperado para a base em questão. Mesmo assim, o método não obteve o desempenho mencionado pelo autor, destacando-se o resultado ruim na base HRF 88,89%. Sem o ajuste de escala, os resultados foram ainda piores. Já a transformada de Hough na imagem inteira obteve um bom desempenho, mas em função dos melhores resultados na base Messidor, o filtro de energia associada a transformada de Hough é o método escolhido para as próximas etapas. Não são realizadas maiores comparações pois o objetivo de localizar o disco é usar essa informação nas próximas etapas e os resultados mostram que o método conseguiu localizar o disco satisfatoriamente.

Tabela 6.1: Taxa de acerto na localização do disco óptico

Base	Método			
	Filtro de energia	Hough	Abdullah	Energia + Hough Medial
DIARETDB1	85.39	94.38	92.13	94.38
DRIVE	100	100	100	100
HRF	100	100	88.89	100
Messidor	98.75	97.75	93.58	98.5

6.2 Resultados em segmentação do disco óptico

O experimento envolveu a localização automática e segmentação do disco óptico na base Messidor. A segmentação foi avaliada de acordo com a *accuracy*, *sensitivity* e *overlapping score* (*S*). Três *roughness index* foram testados: HRI, proposto por Mookiah et al. (2012), SHRI, proposto por Xie et al. (2015) e 3DMHRI, que é o método proposto no presente trabalho.

Também testamos a versão A-IFS destes métodos: FHRI, SFHRI e 3DMFHRI. Os procedimentos de pré-processamento e pós-processamento foram usados igualmente em todos os métodos.

O método proposto alcançou uma *accuracy* de 99,59% na base Messidor com um desvio padrão de 0,005. Como a localização do disco óptico não foi bem sucedida em 18 imagens, fizemos um experimento de segmentação semi-automática, assim como Dai et al. (2017), que realiza a localização manual do disco nas imagens que não geraram a localização correta. No presente estudo a segmentação semi-automática foi realizada com base na marcação do centro do disco e alcançou 99,70% de *accuracy*. A Tabela 6.2 mostra os resultados da segmentação automática e semi-automática para todas as formas de *roughness index* avaliadas. As melhores medidas de *accuracy*, *sensitivity* e *overlapping score* são observadas em 3DMFHRI, na segmentação automática e também na segmentação semi-automática. Destaca-se a ampla diferença na *sensitivity* obtida pelo 3DMHRI e 3DMFHRI em relação aos outros *roughness index*. A diferença entre o 3DMHRI e 3DMFHRI é bastante sutil e concentra-se somente na *sensitivity* isso significa que este método tem melhor capacidade em encontrar o disco óptico.

A Tabela 6.3¹ apresenta medidas obtidas na segmentação do disco óptico em diversos trabalhos. Considerando apenas os trabalhos que utilizam a base Messidor, conseguimos os melhores resultados observados, enquanto que uma análise mais ampla, considerando outras bases, também podemos considerar os resultados satisfatórios, pois trabalhos com medidas melhores usam bases pequenas (DRIVE, com 40 imagens, e STARE, com 89 imagens). Já a Figura 6.1 apresenta algumas das imagens segmentadas: imagens de baixo contraste apresentaram o maior desafio para o método, enquanto que os resultados para imagens de alto contraste foram muito próximos daqueles obtidos pelo especialista.

Tabela 6.2: Comparação dos resultados entre os diferentes tipos de *roughness index*, em segmentação automática e semi-automática.


<i>Roughness Index</i>	Automática			Semi-automática		
	<i>SN</i>	<i>Acc</i>	<i>S</i>	<i>SN</i>	<i>Acc</i>	<i>S</i>
HRI	0.8839	0.9957	0.8339	0.9159	0.9969	0.8692
FHRI	0.8819	0.9957	0.8340	0.9133	0.9968	0.8667
SHRI	0.8574	0.9954	0.8202	0.8901	0.9966	0.8572
SFHRI	0.8592	0.9955	0.8219	0.8912	0.9966	0.8569
3DMHRI	0.9141	0.9959	0.8440	0.9408	0.9970	0.8778
3DMFHRI	0.9156	0.9959	0.8444	0.9432	0.9970	0.8778

¹ Adaptada de Al-Bander et al. (2018), excluindo informações sobre a fóvea e adicionando resultados de outros estudos. Observa-se neste caso, que o tempo é um parâmetro pouco útil para efeito de comparação, uma vez que a natureza do hardware utilizada nos experimentos é bastante diversa.

Tabela 6.3: Comparação do método proposto com outros métodos na literatura. Fonte: adaptada de Al-Bander et al. (2018)

Autor	Método	Taxa de sucesso	Tempo	Base de dados
Hoover e Goldbaum (2003)	Relationship between OD and blood vessels, fuzzy convergence algorithm	Acc: 89%	4m.	STARE
Foracchia et al. (2004)	Geometrical model, blood vessels direction	Acc: 97.53%	2m.	STARE
Fleming et al. (2007)	Visual characteristics of blood vessels, fovea, and OD	Acc: 98.4%	2m.	Local(1)
Tobin et al. (2007)	Characteristics of blood vessels in relation to OD position	Acc: 90.4%		Local(2)
Niemeijer et al. (2007)	Cost function and a point distribution model	Acc: 98.4%	10m.	Local(3)
Youssif et al. (2008)	2D Gaussian matched filter	Acc: 94% Acc: 98.77% Acc: 100%	3.5m	Local(4) STARE DRIVE
Niemeijer et al. (2009)	k-NN regressor	Acc: 99.4% Acc: 93%	7.6s.	Local(3) Local(5)
Zhu et al. (2010)	Sobel operator, Hough transform	Acc: 90%		DRIVE
Lu (2011)	Circular transformation	Acc: 99.75% Acc: 97.5% Acc: 98.77%	5s. 5s.	STARE ARIA Messidor
Yu et al. (2012)	Template matching technique	Acc: 99%	4.7s.	Messidor
Qureshi et al. (2012)	Combining multiple algorithms	Acc: 97.64% Acc: 97.79% Acc: 100%		DIARETDB0 DIARETDB1 DRIVE
Dehghani et al. (2012)	Template from three histograms	Acc: 100% Acc: 91.36% Acc: 98.9%	27.6 s.	DRIVE STARE Local(6)
Mookiah et al. (2012)	A-IFS Histon	Acc: 93.4%		Local(7)
Morales et al. (2013)	PCA	Acc: 99.47%		Messidor
Harangi e Hajdu (2015)	Ensemble-based framework (combining probability models)	Precision: 98.46% Precision: 98.33%	0.25 s.	DIARETDB0 Messidor
Mary et al. (2015)	Active contour model with gradient vector flow	Hausdorff Distance: 33.49	7.2 s.	RIM-ONE
Mittapalli e Kande (2016)	Implicit region based active contour model	F-score: 0.975		Local(8)
Al-Bander et al. (2018)	Deep neural network	Acc: 97%	0.07 s.	Messidor
Proposed method - (3DMFHRI)	3D A-IFS Histon	Acc: 99.59%	3.74s.	Messidor

* O número de imagens em cada base é: STARE - 81, Local (1) – 1056, Local (2) – 345, Local (3) – 500, Local (4) – 100, DRIVE – 40, Local (5) – 100, Local (6) – 273, Local(7) - 100, Local(8) – 59, RIM-ONE – 169, ARIA – 120, Messidor – 1200, DIARETDB0 – 130, DIARETDB1 – 89.

Figura 6.1: Resultado da segmentação do disco óptico.

Marcação do especialista: contorno azul, marcação do método: contorno verde. (a) Imagem original. (b) HRI. (c) FHRI. (d) SHRI. (e) SFHRI. (f) 3DMHRI. (g) 3DMFHRI.

6.3 Resultados em segmentação dos vasos sanguíneos

Como foi dito anteriormente, os parâmetros ideais foram definidos em: número de neurônios da camada oculta 128, tamanho de bloco 8×8 (64 neurônios na camada de entrada/saída), α como 0,000282 e η definido como 0,009125. O pré-processamento é baseado principalmente em CLAHE e filtro de Wiener, e a quantidade de épocas é 300. A Tabela 6.4 mostra algumas rodadas de treinamento variando apenas número do NCO, uma vez que este tem um grande impacto no desempenho da rede, verifica-se que a partir de 128 neurônios não há garantias de que a *Acc* será maior, assim esse é o número adotado. Observou-se também que o tamanho de bloco 8×8 permite que vasos grossos, médios e finos sejam obtidos com grau de precisão aceitável.

Tabela 6.4: *Accuracy* em função do número de neurônios na camada oculta.

Bloco	α	η	NCO	<i>Acc</i>
8×8	0,000282	0,009125	32	0,9450
			64	0,9468
			80	0,9480
			100	0,9483
			128	0,9487
			140	0,9484
			200	0,9488

A Tabela 6.5 mostra os resultados das métricas *sensitivity* (*SN*), *specificity* (*SP*) e *accuracy* (*Acc*) para cada imagem do conjunto de testes da base DRIVE. Os resultados são apresentados para o primeiro e segundo observador. Levando em consideração que a base apresenta a segmentação manual dos vasos sanguíneos realizada por dois especialistas, as imagens foram classificadas frente a segmentação de cada um deles. É interessante observar que a rede mostrou maior sintonia com a classificação do segundo observador, uma vez que o *Acc* médio foi melhor. Em relação ao primeiro observador, as imagens “03_test” e “15_test” mostram os piores resultados, enquanto as imagens “19_test” e “20_test” mostram os melhores resultados. A imagem “19_test” apresentou a melhor *sensitivity*, detonando a boa capacidade da rede em encontrar os vasos sanguíneos na referida imagem, no entanto, esta métrica deve ser analisada em conjunto com a *specificity*, para a qual se observa o valor 0,9785, o que resulta em uma *Acc* de 0,96, o melhor resultado obtido dentre as imagens da base DRIVE. Já a imagem “15_test” apresenta uma *sensitivity* de 0,7793 com uma *specificity* de 0,9449, o que significa que a rede

encontrou muitos vasos, mas cometeu muitos erros ao considerar outras estruturas como sendo vasos, isso resulta em uma *Acc* de 0,93, bem abaixo da média geral que é 0,9487. Já para o segundo observador os melhores resultados foram nas imagens “04_test” e “10_test”, e o pior resultado também foi na imagem “15_test”: *Acc* de 0,9316, bem abaixo do restante.

Tabela 6.5: Resultados no conjunto TEST da base DRIVE para o primeiro e o segundo observador

Imagem	Primeiro observador			Segundo observador		
	SN	SP	Acc	SN	SP	Acc
01_test	0,726121	0,977002	0,951001	0,744384	0,977392	0,953728
02_test	0,712992	0,982952	0,950968	0,740780	0,986152	0,957553
03_test	0,654425	0,977982	0,939898	0,725706	0,976465	0,950121
04_test	0,673750	0,983836	0,950152	0,720933	0,983378	0,956228
05_test	0,639719	0,988275	0,949883	0,720592	0,987077	0,961608
06_test	0,581673	0,991368	0,944498	0,605714	0,989904	0,947843
07_test	0,640521	0,980612	0,944585	0,745070	0,973456	0,954496
08_test	0,586389	0,984226	0,943743	0,682953	0,978136	0,954878
09_test	0,537788	0,993341	0,950101	0,543746	0,993131	0,950615
10_test	0,670275	0,983253	0,952967	0,742892	0,981534	0,961405
11_test	0,679170	0,975716	0,944544	0,737559	0,976585	0,953236
12_test	0,670972	0,982445	0,951222	0,713709	0,982267	0,957225
13_test	0,612666	0,987032	0,944212	0,611321	0,990110	0,945265
14_test	0,731492	0,971476	0,949517	0,775988	0,969958	0,953560
15_test	0,779368	0,944970	0,930995	0,777096	0,946583	0,931673
16_test	0,659629	0,986913	0,952265	0,693050	0,986314	0,957045
17_test	0,593386	0,988179	0,949519	0,660039	0,987125	0,959075
18_test	0,691019	0,981365	0,954550	0,660071	0,988752	0,953546
19_test	0,798729	0,978514	0,961050	0,723461	0,985030	0,954633
20_test	0,706821	0,983098	0,959210	0,614826	0,989255	0,948487
Média	0,667345	0,981128	0,948744	0,696994	0,98143	0,953111


A Tabela 6.6 sintetiza um comparativo entre as medidas obtidas de diversos trabalhos, considerando a sensibilidade, especificidade, *accuracy* e área sob a curva ROC. Observa-se que os resultados obtidos pelo método proposto se sobrepõem aos resultados de estudos baseados em aprendizado de máquina, como é o caso de Liskowski e Krawiec (2016), Maji et al. (2016), Vega et al. (2015), e outros métodos (Azzopardi et al. (2015), Fraz et al. (2012a), Marin et al. (2011), Hassanien et al. (2015), Nguyen et al. (2013), Zhao et al. (2014), etc). Mas não consegue superar os trabalhos de Al-Rawi e Karajeh (2007), Ricci e Perfetti (2007), Lupaşcu et al. (2010), Fathi e Naghsh-Nilchi (2013) e Wang et al. (2015). Al-Rawi e Karajeh (2007) unem dois excelentes métodos que são o *matched filter* e aprendizado por meio de métodos bioinspirados, já Ricci e Perfetti (2007) usam operadores de linha e SVM; Lupaşcu et al. (2010) usam informações sobre a estrutura de intensidade local, propriedades espaciais e geometria em múltiplas escalas e um classificador AdaBoost; Fathi e Naghsh-Nilchi (2013) usam wavelet e

operador de estrutura circular e Wang et al. (2015) utilizam CNN e *Random Forest*. Em outras palavras, o método proposto é superado apenas por combinações de métodos reconhecidamente eficientes, ressaltando se dessa forma a importância do pré-processamento e ajuste apresentados.

Tabela 6.6: Comparação do método proposto com outros métodos do estado da arte - base DRIVE.

Método	SN	SP	Acc	AUC
Método proposto (1º observador humano)	0.6673	0.9811	0.9487	
Método proposto (2º observador humano)	0.6969	0.9814	0.9531	
Liskowski e Krawiec (2016)	0.7819	0.9748	0.9472	
Maji et al. (2016)	-	-	0.9470	
Azzopardi et al. (2015)	0.7655	0.9704	0.9442	
Fraz et al. (2012a)	0.7302	0.9742	0.9422	
Vega et al. (2015)	0.7444	0.9600	0.9412	
Orlando e Blaschko (2014)	0.7897	0.9684	-	
Hassanien et al. (2015)	0.7210	0.9710	0.9388	
Chaudhuri et al. (1989)	-	-	0.8773	0.7878
Zana e Klein (2001)	-	-	0.9377	-
Niemeijer et al. (2004)	0.7145	-	0.9416	0.9294
Staal et al. (2004)			0.9442	0.952
Soares et al. (2006)	-	-	0.9466	0.9614
Al-Rawi e Karajeh (2007)	-	-	0.9535	0.9435
Ricci e Perfetti (2007)	-	-	0.9563	0.9558
Martinez-Perez et al. (2007)	0.7246	0.9655	0.9344	-
Al-Rawi e Karajeh (2007)	-	-	0.9422	0.9582
Cinsdikici e Aydın (2009)	-	-	0.9293	0.9407
Osareh e Shadgar (2009)	-	-	-	0.9650
Lupaşcu et al. (2010)	-	-	0.9597	0.9561
Vlachos e Dermatas (2010)	0.747	0.955	0.929	-
Xu e Luo (2010)	0.7760	-	0.9328	-
Marin et al. (2011)	0.7067	0.9801	0.9452	0.9588
You et al. (2011)	0.7410	0.9751	0.9434	
Fathi e Naghsh-Nilchi (2013)	0.7768	0.9759	0.9581	0.9516
Nguyen et al. (2013)	-	-	0.9404	-
Franklin e Rajan (2014a)	-	-	0.9503	
Zhao et al. (2014)	-	-	0.9477	
Zhang et al. (2015)	0.7812	0.9668	0.9505	-
Wang et al. (2015)	0.8173	0.9733	0.9767	0.9475
Singh e Srivastava (2016)	-	-	-	0.9287
Kar e Maity (2016)	-	-	-	0.9616

A Figura 6.2 mostra a segmentação de algumas das imagens. Observa-se que as imagens que geram resultados piores têm um fundo de olho menos uniforme, devido a lesões, pigmentação e efeitos de iluminação, é o caso da imagem “15_test”. A imagem “03_test” também possui muitos vasos finos, o que dificulta a tomada de decisões pela rede.

Figura 6.2: Resultado da segmentação dos vasos sanguíneos

A primeira coluna contém imagens originais: (a) “03_test”, (e) “15_test”, (i) “19_test”, (m) “20_test”; na segunda coluna, os respectivos pré-processamentos, na terceira coluna os respectivos *ground truths* e na última coluna os respectivos resultados obtidos pelo método.

6.4 Discussão

6.4.1 Considerações sobre a localização e segmentação do disco óptico

O método de localização proposto neste trabalho alcançou uma taxa de acerto de 98,5% para o critério 1R, que é bastante próximo do resultado de 98,8% alcançado por Suero et al. (2013) na base Messidor. A localização prévia é necessária para a redução da região de interesse. O maior gargalo na segmentação do disco óptico é o cálculo da distância entre um pixel e seus vizinhos, com a localização prévia, esse cálculo é feito para uma área reduzida.

As imagens da base Messidor variam em tamanho e contraste, algumas apresentam sub ou superexposição, enquanto outras contêm sinais oculares ou ruído. Portanto, segmentar essa dados é bastante desafiador. O método de segmentação proposto mostrou-se robusto e eficiente e foi mais preciso do que várias outras metodologias (por exemplo, *deep neural network*, Al-Bander et al. (2018); transformada circular, Lu (2011); *template matching*, Yu et al. (2012); PCA, Morales et al. (2013), Harangi e Hajdu (2015) e outros, Tabela 6.3. Considerando a comparação com outras bases de dados, nossa metodologia foi superior à classificação de pixels baseada em aprendizado apresentada por Niemeijer et al. (2009); geometria vascular, Niemeijer et al. (2007); Tobin et al. (2007); Youssif et al. (2008); e a transformada de Hough circular, Zhu et al. (2010). A *overlapping score* também apresentou bons resultados, Tabela 6.8.

Tabela 6.8: Comparativo da *Overlapping score* na base Messidor

Methods	<i>S</i>
Dai et al. (2017)	0.91
Dashtbozorg et al. (2015)	0.89
Sarathi et al. (2016)	0.89
Giachetti et al. (2014)	0.88
Marin et al. (2015)	0.87
Muramatsu et al. (2011a)	0.87
Aquino et al. (2010)	0.86
Yu et al. (2012)	0.84
Roychowdhury et al. (2016)	0.84
Morales et al. (2013)	0.82
Método proposto	0.84
Método proposto semi-automático	0.87

Uma comparação com Mookiah et al. (2012) é relevante dada sua similaridade com o presente estudo. Embora não se possa comparar diretamente, pois Mookiah et al. usa uma base de dados própria, é válido destacar que a precisão do nosso método (99,59%) foi claramente maior do que a obtida por Mookiah et al., (93,4%). Na prática, a segmentação tradicional baseada

no *roughness index*/histon gera uma esfera de cores semelhantes no espaço RGB, enquanto os histogramas 3D agregam todos os canais de cores uma estrutura única, garantindo informações completas sobre cores. Quando o histograma 3D é representado em um dimensão, a correlação entre as cores dentro do espaço de cores do objeto segmentado é ainda mais evidente. Os artefatos gerados pelo estágio de pré-processamento se comportam como super pixels que podem ser separados pelo algoritmo de segmentação.

As vantagens dos métodos de segmentação baseados em histograma são, velocidade, auto-adaptação e simplicidade. Entre os métodos baseados em *roughness index*, os melhores resultados foram obtidos 3DMFHRI, que é baseado na representação A-IFS da imagem usando um histograma 3D, histon 3D, e pré-processamento morfológico. A cor também melhora a segmentação, por exemplo, SHRI produziu os piores resultados entre as três variações. O teste semi-automático, em que o centro é marcado manualmente, alcançou 99,70% de precisão e 87% de *overlapping score*.

O sucesso da nossa metodologia foi alcançado através de testes e ajustes exaustivos. Por exemplo, o valor necessário para classificar valor do *roughness index* como pico foi de 87% da média todo o RI, enquanto a distância mínima foi de 14.

6.4.2 Considerações sobre a segmentação dos vasos sanguíneos

O grande desafio neste trabalho está associado à determinação dos parâmetros ótimos. Se a escolha dos parâmetros for apropriada, o modelo pode fornecer à rede grande poder de generalização, mas se a escolha não for apropriada, o processo de convergência pode ser lento e os resultados podem não atingir os objetivos desejados. O desempenho na segmentação dos vasos sanguíneos obtidos em nossa implementação é satisfatório em relação às métricas utilizadas na literatura, e os resultados são equivalentes ao estado da arte em vários métodos. O método proposto produz melhores medidas de especificidade e precisão do que as da arquitetura de redes de aprendizagem profunda proposta por Liskowski e Krawiec (2016) e muitos outros trabalhos listados na Tabela 6.6.

Um ajuste importante foi obtido em relação ao tamanho do bloco aplicado à imagem de entrada. Blocos de tamanho 8×8 foram capazes de encontrar vasos médios e grossos e muitos dos vasos finos. Blocos muito grandes não são capazes de encontrar vasos finos, enquanto que blocos muito pequenos causam sobrecarga na rede. Em geral, é difícil encontrar vasos finos usando métodos baseados em aprendizado. Dado o tamanho do bloco, o número de neurônios na

camada de entrada, é possível derivar uma relação para o número de neurônios na camada oculta, um valor de 128 resultou em excelente desempenho. Este resultado é semelhante ao método de Kolmogorov, onde $NCO = 2n + 1$, n sendo o número de neurônios na camada de entrada, (FAUSETT, 1994). Aumentar esse valor não leva a grandes ganhos no treinamento da rede.

O pré-processamento realizado é crítico para o sucesso do método e não é fácil de se obter. Os vasos sanguíneos precisam ser realçados sem que isso cause o realce de marcas anatômicas de intensidade semelhante, como a fóvea. Para contornar o problema de baixo contraste, a presença de ruído, etc, utilizamos o filtro Wiener, morfologia matemática, CLAHE e o filtro da média. O ajuste dos parâmetros para cada filtro consumiu tempo e exigiu muitas tentativas. O filtro Wiener mostrou-se eficiente para imagens de fundo de olho, pois utiliza estimativa adaptativa em pixels de uma vizinhança local, permitindo que a resposta do filtro seja controlada em relação à espessura dos vasos sanguíneos. O CLAHE também opera de maneira semelhante, normalizando o histograma em uma pequena vizinhança. Os parâmetros para cada uma dessas técnicas foram cuidadosamente estabelecidos.

Este trabalho apresentou a segmentação de imagens de fundo de olho com ênfase em elementos fisiológicos. De uma maneira geral a segmentação de retinografias é realizada por partes, com métodos específicos a cada elemento fisiológico ou patológico a fim de obter a máxima precisão na segmentação e contornar o problema do baixo contraste observado nestas imagens. A segmentação dos elementos fisiológicos do fundo de olho foi dividida em três etapas: localização do disco óptico, segmentação do disco óptico e segmentação dos vasos sanguíneos.

A primeira etapa foi realizada conforme sugerido por diversos pesquisadores em que se utilizava um método simples e rápido para uma aproximação grosseira e depois um método mais apurado para uma localização eficiente, sendo escolhido o filtro de energia como método rápido e transformada de Hough circular como método de preciso, resultando em um método híbrido baseado em intensidade e forma.

Para a segunda etapa, que é a segmentação do disco óptico, foi apresentada uma solução baseada em conjuntos aproximativos - *rough sets*. Nesta abordagem é utilizado o histon, uma variação do histograma, que contém informação espacial incrustada entre as informações de frequência. Da relação entre o histograma e o histon, surge o *roughness index* que é o instrumento utilizado para se obter os *thresholds*, uma vez que o mesmo responde às mudanças abruptas de intensidade sob a forma de vales. Diversas melhorias podem ser agregadas a esta técnica, dentre as principais, tem-se: fuzzy sets, suavização do histograma e do histon por LPR e melhoria da performance da segmentação em cores por agregação dos três canais em um único histograma/histon. Assim, optou-se por esta última alternativa, que demandou também a eliminação dos vasos sanguíneos, para a qual foi adotada a morfologia matemática. O algoritmo que separa em regiões foi adaptado ao processamento morfológico resultando em uma segmentação suave.

Resolvida esta questão, a etapa seguinte é separar o disco do restante da imagem, geralmente se utiliza características de cor, tamanho ou forma. Foi adotada uma proporção em relação ao tamanho da imagem, uma vez que o método proposto deve funcionar bem em diversas bases com diferentes resoluções.

Um fato importante pouco mencionado a respeito dessa tarefa é a dificuldade em separar o lado nasal do disco do restante da retina, como foi dito anteriormente está é uma área com grande vascularização, sendo bastante comum apresentar a mesma intensidade que o fundo de olho, portanto, isso foi solucionado com uma correção, na qual uma elipse foi traçada com base em informações da forma encontrada na segmentação.

A terceira e última etapa, que é a segmentação dos vasos sanguíneos. A identificação da estrutura vascular em imagens de fundo de olho é um passo importante na triagem de distúrbios da retina. Neste trabalho, foi projetada uma rede neural artificial multicamadas, que foi combinada com técnicas de pré-processamento e pós-processamento de imagens. A metodologia proposta foi testada na base Drive. Um dos passos mais importantes nas redes neurais é o pré-processamento de dados de entrada, que varia de um contexto para outro. Os resultados obtidos são encorajadores para quase todas as métricas.

Portanto, as principais contribuições do presente trabalho são: nova implementação da transformada de Hough circular, contemplando a imprecisão dos contornos do disco óptico; método híbrido eficiente de localização do disco óptico; algoritmo de segmentação com base em *roughness index* que proporciona uma melhor correlação das cores; modelo eficiente de pré-processamento de imagens para uso em métodos de aprendizado e ajuste eficiente de uma rede neural para detectar vasos sanguíneos.

A segmentação foi avaliada utilizando o *ground truth* disponibilizado pelas bases públicas e por pesquisadores. A partir deste *ground truth*, que é a segmentação manual, foram obtidas as medidas SN, SP, Acc e *S score*. Sendo obtidos bons resultados em todas as etapas listadas.

E como trabalhos futuros, será implementado um novo método baseado em *roughness index 3D* e suavização por LPR; serão desenvolvidas redes convolucionais para segmentar o disco óptico, os vasos sanguíneos e microaneurismas possibilitando a criação de um sistema automático de diagnóstico de retinopatia diabética.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDULLAH, M.; FRAZ, M. M.; BARMAN, S. A. Localization and segmentation of optic disc in retinal images using circular Hough transform and grow-cut algorithm. *PeerJ 4:e2003*, v. 4, n. 1, p. 1–22, 2016. doi:<<http://dx.doi.org/10.7717/peerj.2003>>.

ACHARYA, U. R.; NG, E. Y. K.; EUGENE, L. W. J.; NORONHA, K. P.; MIN, L. C.; NAYAK, K. P.; BHANDARY, S. V. Decision support system for the glaucoma using Gabor transformation. *Biomedical Signal Processing and Control*, v. 15, p. 18–26, 2015. ISSN 17468108. doi:<<http://dx.doi.org/10.1016/j.bspc.2014.09.004>>.

AL-BANDER, B.; AL-NUAIMY, W.; WILLIAMS, B. M.; ZHENG, Y. Multiscale sequential convolutional neural networks for simultaneous detection of fovea and optic disc. *Biomedical Signal Processing and Control*, Elsevier Ltd, v. 40, p. 91–101, 2018. ISSN 17468108. doi:<<http://dx.doi.org/10.1016/j.bspc.2017.09.008>>.

AL-RAWI, M.; KARAJEH, H. Genetic algorithm matched filter optimization for automated detection of blood vessels from digital retinal images. *Computer Methods and Programs in Biomedicine*, v. 87, n. 3, p. 248 – 253, 2007. ISSN 0169-2607. doi:<<http://dx.doi.org/10.1016/j.cmpb.2007.05.012>>.

AQUINO, A.; GEGÚNDEZ-ARIAS, M. E.; MARÍN, D. Detecting the Optic Disc Boundary in Digital Fundus Images Using Morphological, Edge Detection, and Feature Extraction Techniques. *IEEE Transactions on Medical Imaging*, v. 29, n. 11, p. 1860–1869, 2010. doi:<<http://dx.doi.org/10.1109/tmi.2010.2053042>>.

ASAD, A. H.; AMRY, E. E.; HASSANIEN, A. E. Retinal vessels segmentation based on water flooding model. In: *Computer Engineering Conference (ICENCO), 2013 9th International*. [S.l.: s.n.], 2013. p. 43–48. doi:<<http://dx.doi.org/10.1109/ICENCO.2013.6736474>>.

AZZOPARDI, G.; STRISCIUGLIO, N.; VENTO, M.; PETKOV, N. Trainable COSFIRE filters for vessel delineation with application to retinal images. *Medical Image Analysis*, Elsevier B.V., v. 19, n. 1, p. 46–57, 2015. ISSN 13618423. doi:<<http://dx.doi.org/10.1016/j.media.2014.08.002>>.

BALLARD, D. H. Generalizing the hough transform to detect arbitrary shapes. *Pattern Recognition*, v. 13, n. 2, p. 111–122, 1981. doi:<[https://doi.org/10.1016/0031-3203\(81\)90009-1](https://doi.org/10.1016/0031-3203(81)90009-1)>.

BUDAI, A.; AICHERT, A.; VYMAZAL, B.; HORNEGGER, J.; MICHELSON, G. Optic disk localization using fast radial symmetry transform. In: *Proceedings of the 26th IEEE International Symposium on Computer-Based Medical Systems*. [S.l.: s.n.], 2013. p. 59–64. ISSN 1063-7125. doi:<<http://dx.doi.org/10.1109/CBMS.2013.6627765>>.

BUDAI, A.; BOCK, R.; MAIER, A.; HORNEGGER, J.; MICHELSON, G. Robust vessel segmentation in fundus images. *International Journal of Biomedical Imaging*, v. 2013, p. 1–11, 2013. doi:<<http://dx.doi.org/10.1155/2013/154860>>.

BUDAI, A.; LAURIK, L.; HORNEGGER, J.; SOMFAI, G. M.; MICHELSON, G. Probability map based localization of optic disk. In: *2012 19th International Conference on Systems, Signals and Image Processing (IWSSIP)*. [s.n.], 2012. p. 568–571. ISSN 2157-8672. Disponível em: <<http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=6208205>>.

Centers for Disease Control Prevention. *Diabetes 2014 Report Card*. Atlanta, 2014. US Dept of Health and Human Services. Disponível em: <<http://www.cdc.gov/diabetes/pdfs/library/diabetesreportcard2014.pdf>>.

CHAUDHURI, S.; CHATTERJEE, S.; KATZ, N.; NELSON, M.; GOLDBAUM, M. Detection of blood vessels in retinal images using two-dimensional matched filters. *IEEE transactions on medical imaging*, v. 8, n. 3, p. 263–269, 1989. ISSN 0278-0062. doi:<<http://dx.doi.org/10.1109/42.34715>>.

CHEN, B.; CHEN, Y.; SHAO, Z.; TONG, T.; LUO, L. Blood vessel enhancement via multi-dictionary and sparse coding: Application to retinal vessel enhancing. *Neurocomputing*, p. –, 2016. ISSN 0925-2312. doi:<<http://dx.doi.org/10.1016/j.neucom.2016.03.012>>.

CHENG, H. D.; JIANG, X. H.; WANG, J. Color image segmentation based on homogram thresholding and region merging. v. 35, p. 373–393, 2002. doi:<[https://doi.org/10.1016/S0031-3203\(01\)00054-1](https://doi.org/10.1016/S0031-3203(01)00054-1)>.

CHENG, J.; LIU, J.; XU, Y.; YIN, F.; WONG, D. W. K.; TAN, N. M.; TAO, D.; CHENG, C. Y.; AUNG, T.; WONG, T. Y. Superpixel classification based optic disc and optic cup segmentation for glaucoma screening. *IEEE Transactions on Medical Imaging*, v. 32, n. 6, p. 1019–1032, June 2013. ISSN 0278-0062. doi:<<http://dx.doi.org/10.1109/TMI.2013.2247770>>.

CHIRANJEEVI, P.; SENGUPTA, S. Robust detection of moving objects in video sequences through rough set theory framework. *Image and Vision Computing*, Elsevier B.V., v. 30, n. 11, p. 829–842, 2012. ISSN 02628856. doi:<<http://dx.doi.org/10.1016/j.imavis.2012.06.015>>.

CHRÁSTEK, R.; WOLF, M.; DONATH, K.; NIEMANN, H.; PAULUS, D.; HOTHORN, T.; LAUSEN, B.; LÄMMER, R.; MARDIN, C. Y.; MICHELSON, G. Automated segmentation of the optic nerve head for diagnosis of glaucoma. *Medical Image Analysis*, v. 9, n. 4, p. 297–314, 2005. ISSN 1361-8415. doi:<<http://dx.doi.org/10.1016/j.media.2004.12.004>>.

CINSDIKICI, M. G.; AYDIN, D. Detection of blood vessels in ophthalmoscope images using mf/ant (matched filter/ant colony) algorithm. *Computer Methods and Programs in Biomedicine*, v. 96, n. 2, p. 85 – 95, 2009. ISSN 0169-2607. doi:<<http://dx.doi.org/10.1016/j.cmpb.2009.04.005>>.

DAI, B.; WU, X.; BU, W. Optic disc segmentation based on variational model with multiple energies. *Pattern Recognition*, Elsevier, v. 64, n. 3, p. 226–235, apr 2017. ISSN 00313203. doi:<<http://dx.doi.org/10.1016/j.patcog.2016.11.017>>.

DASHTBOZORG, B.; MENDONÇA, A. M.; CAMPILHO, A. Optic disc segmentation using the sliding band filter. *Computers in Biology and Medicine*, v. 56, p. 1–12, 2015. ISSN 0010-4825. doi:<<http://dx.doi.org/10.1016/j.combiomed.2014.10.009>>.

DECENCIÈRE, E.; ZHANG, X.; CAZUGUEL, G.; LAY, B.; COCHENER, B.; TRONE, C.; GAIN, P.; ORDONEZ, R.; MASSIN, P.; ERGINAY, A.; CHARTON, B.; KLEIN, J.-C. Feedback on a publicly distributed database: the messidor database. *Image Analysis & Stereology*, v. 33, n. 3, p. 231–234, ago. 2014. ISSN 1854-5165. doi:<<http://dx.doi.org/10.5566/ias.1155>>.

DEHGHANI, A.; MOGHADDAM, H. A.; MOIN, M. S. Optic disc localization in retinal images using histogram matching. *Journal on Image and Video Processing*, v. 2012, n. 1, p. 1–11, 2012. doi:<<https://doi.org/10.1186/1687-5281-2012-19>>.

DORION, T. *Manual de Exame do Fundo de Olho*. 1. ed. Barueri - SP: Manole, 2002. ISBN 85-204-1203-3.

ESMAEILI, M.; RABBANI, H.; DEHNAVI, A. M. Automatic optic disk boundary extraction by the use of curvelet transform and deformable variational level set model. *Pattern Recognition*, Elsevier, v. 45, n. 7, p. 2832–2842, 2012. ISSN 00313203. doi:<<http://dx.doi.org/10.1016/j.patcog.2012.01.002>>.

FAN, Z.; LI, F.; RONG, Y.; LI, W.; CAI, X.; LIN, H. Detecting optic disk based on adaboost and active geometric shape model. In: *Cyber Technology in Automation, Control, and Intelligent Systems (CYBER), 2015 IEEE International Conference on*. [S.l.: s.n.], 2015. p. 311–316. doi:<<https://doi.org/10.1109/cyber.2015.7287954>>.

FARNELL, D. J. J.; HATFIELD, F. N.; KNOX, P.; REAKES, M.; SPENCER, S.; PARRY, D.; HARDING, S. P. Enhancement of blood vessels in digital fundus photographs via the application of multiscale line operators. *Journal of the Franklin Institute*, v. 345, n. 7, p. 748–765, 2008. ISSN 00160032. doi:<<http://dx.doi.org/10.1016/j.jfranklin.2008.04.009>>.

FAROKHIAN, F.; DEMIREL, H. Fast detection and segmentation in retinal blood vessels using gabor filters. In: *22nd Signal Processing and Communications Applications Conference (SIU)*. [S.l.: s.n.], 2014. p. 1507–1511. ISSN 2165-0608. doi:<<http://dx.doi.org/10.1109/SIU.2014.6830527>>.

FATHI, A.; NAGHSH-NILCHI, A. R. Automatic wavelet-based retinal blood vessels segmentation and vessel diameter estimation. *Biomedical Signal Processing and Control*, v. 8, n. 1, p. 71–80, 2013. ISSN 1746-8094. doi:<<http://dx.doi.org/10.1016/j.bspc.2012.05.005>>.

FAUSETT, L. *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. Upper Saddle River: Prentice-Hall, Inc., 1994. ISBN 0-13-334186-0.

FLEMING, A. D.; GOATMAN, K. A.; PHILIP, S.; OLSON, J. A.; SHARP, P. F. Automatic detection of retinal anatomy to assist diabetic retinopathy screening. *Physics in Medicine and Biology*, v. 52, n. 2, p. 331–345, 2007. ISSN 00319155. doi:<<http://dx.doi.org/10.1088/0031-9155/52/2/002>>.

FORACCHIA, M.; GRISAN, E.; RUGGERI, A. Detection of optic disc in retinal images by means of a geometrical model of vessel structure. *IEEE Transactions on Medical Imaging*, v. 23, n. 10, p. 1189–1195, 2004. ISSN 02780062. doi:<<http://dx.doi.org/10.1109/TMI.2004.829331>>.

FRANKLIN, S. W.; RAJAN, S. E. Computerized screening of diabetic retinopathy employing blood vessel segmentation in retinal images. *Biocybernetics and Biomedical Engineering*, v. 34, n. 2, p. 117 – 124, 2014. ISSN 0208-5216. doi:<<http://dx.doi.org/10.1016/j.bbe.2014.01.004>>.

FRANKLIN, S. W.; RAJAN, S. E. Retinal vessel segmentation employing {ANN} technique by gabor and moment invariants-based features. *Applied Soft Computing*, v. 22, p. 94 – 100, 2014. ISSN 1568-4946. doi:<<http://dx.doi.org/10.1016/j.asoc.2014.04.024>>.

FRAZ, M.; BARMAN, S.; REMAGNINO, P.; HOPPE, A.; BASIT, A.; UYYANONVARA, B.; RUDNICKA, A.; OWEN, C. An approach to localize the retinal blood vessels using bit planes and centerline detection. *Computer Methods and Programs in Biomedicine*, v. 108, n. 2, p. 600 – 616, 2012. ISSN 0169-2607. doi:<<http://dx.doi.org/10.1016/j.cmpb.2011.08.009>>.

FRAZ, M.; REMAGNINO, P.; HOPPE, A.; UYYANONVARA, B.; RUDNICKA, A.; OWEN, C.; BARMAN, S. Blood vessel segmentation methodologies in retinal images – a survey. *Computer Methods and Programs in Biomedicine*, v. 108, n. 1, p. 407 – 433, 2012. ISSN 0169-2607. doi:<<http://dx.doi.org/10.1016/j.cmpb.2012.03.009>>.

FUENTE-ARRIAGA, J. A. de la; FELIPE-RIVERÓN, E. M.; GARDUÑO-CALDERÓN, E. Application of vascular bundle displacement in the optic disc for glaucoma detection using fundus images. *Computers in Biology and Medicine*, v. 47, p. 27–35, 2014. ISSN 0010-4825. doi:<<http://dx.doi.org/10.1016/j.compbiomed.2014.01.005>>.

GIACHETTI, A.; BALLERINI, L.; TRUCCO, E. Accurate and reliable segmentation of the optic disc in digital fundus images the optic disc in digital fundus images. *Journal of Medical Imaging*, 2014. doi:<<https://doi.org/10.1117/1.jmi.1.2.024001>>.

GONZALEZ, R. C.; WOODS, R. E. *Processamento Digital de Imagens*. 3ª. ed. São Paulo: Pearson Prentice Hall, 2010.

GUO, L.; YANG, J. J.; PENG, L.; LI, J.; LIANG, Q. A computer-aided healthcare system for cataract classification and grading based on fundus image analysis. *Computers in Industry*, v. 69, p. 72–80, 2015. ISSN 01663615. doi:<<http://dx.doi.org/10.1016/j.compind.2014.09.005>>.

HAJER, J.; KAMEL, H.; NOUREDDINE, E. Localization of the optic disk in retinal image using the “watersnake”. In: *Computer and Communication Engineering, 2008. ICCCE 2008. International Conference on*. [S.l.: s.n.], 2008. p. 947–951. doi:<<http://dx.doi.org/10.1109/ICCCE.2008.4580746>>.

HARANGI, B.; HAJDU, A. Detection of the optic disc in fundus images by combining probability models. *Computers in Biology and Medicine*, v. 65, p. 10–24, 2015. ISSN 0010-4825. doi:<<http://dx.doi.org/10.1016/j.compbiomed.2015.07.002>>.

HASSANIEN, A. E.; EMARY, E.; ZAWBAA, H. M. Retinal blood vessel localization approach based on bee colony swarm optimization, fuzzy c-means and pattern search. *Journal of Visual Communication and Image Representation*, v. 31, p. 186 – 196, 2015. ISSN 1047-3203. doi:<<http://dx.doi.org/10.1016/j.jvcir.2015.06.019>>.

HENDRICK, A. M.; GIBSON, M. V.; KULSHRESHTHA, A. Diabetic Retinopathy. *Primary Care - Clinics in Office Practice*, v. 42, n. 3, p. 451–464, 2015. ISSN 1558299X. doi:<<http://dx.doi.org/10.1016/j.pop.2015.05.005>>.

HOOVER, A.; GOLDBAUM, M. Locating the optic nerve in a retinal image using the fuzzy convergence of the blood vessels. *Medical Imaging, IEEE Transactions on*, v. 22, n. 8, p. 951–958, 2003. ISSN 0278-0062. doi:<<http://dx.doi.org/10.1109/tmi.2003.815900>>.

HOOVER, A. D.; KOUZNETSOVA, V.; GOLDBAUM, M. Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response. *IEEE Transactions on Medical Imaging*, v. 19, n. 3, p. 203–210, March 2000. ISSN 0278-0062. doi:<<https://doi.org/10.1109/42.845178>>.

HOUGH, V.; PAUL, C. *Method and means for recognizing complex patterns*. 1962. Patent 3069654. Disponível em: <<http://www.freepatentsonline.com/3069654.html>>.

HSIAO, H.-K.; LIU, C.-C.; YU, C.-Y.; KUO, S.-W.; YU, S.-S. A novel optic disc detection scheme on retinal images. *Expert Systems with Applications*, Elsevier Ltd, v. 39, n. 12, p. 10600–10606, 2012. ISSN 09574174. doi:<<http://dx.doi.org/10.1016/j.eswa.2012.02.157>>.

KAR, S. S.; MAITY, S. P. Blood vessel extraction and optic disc removal using curvelet transform and kernel fuzzy c-means. *Computers in Biology and Medicine*, v. 70, p. 174–189, 2016. ISSN 0010-4825. doi:<<http://dx.doi.org/10.1016/j.compbiomed.2015.12.018>>.

KARKUZHALI, S.; MANIMEGALAI, D.; SANTHI, D. Effective Segmentation of Optic Disc in Retinal images for diagnosing Eye Diseases that leads to Blindness. *Biomedical and Pharmacology*, v. 8, n. 1, p. 427–434, 2015. doi:<<https://doi.org/10.13005/bpj/631>>.

KAUPPI, T.; KALESNYKIENE, V.; KAMARAINEN, J.-k.; LENSU, L.; SORRI, I. *DIARETDB1 diabetic retinopathy database and evaluation protocol*. [S.l.], 2007. 1–18 p. doi:<<https://doi.org/10.5244/c.21.15>>.

KAUPPI, T.; KAMARAINEN, J. K.; LENSU, L.; KALESNYKIENE, V.; SORRI, I.; UUSITALO, H.; KÄLVIÄINEN, H. A framework for constructing benchmark databases and protocols for retinopathy in medical image analysis. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, v. 7751 LNCS, p. 832–843, 2013. ISSN 03029743. doi:<http://dx.doi.org/10.1007/978-3-642-36669-7_101>.

KÖSE, C.; ŞEVIK, U.; IKIBAŞ, C.; ERDÖL, H. Simple methods for segmentation and measurement of diabetic retinopathy lesions in retinal fundus images. *Computer Methods and Programs in Biomedicine*, v. 107, n. 2, p. 274–293, 2012. ISSN 01692607. doi:<<http://dx.doi.org/10.1016/j.cmpb.2011.06.007>>.

KOUKOUNIS, D.; TTOFIS, C.; PAPADOPOULOS, A.; THEOCHARIDES, T. A high performance hardware architecture for portable, low-power retinal vessel segmentation. *Integration, the {VLSI} Journal*, v. 47, n. 3, p. 377 – 386, 2014. ISSN 0167-9260. Special issue: {VLSI} for the new era. doi:<<http://dx.doi.org/10.1016/j.vlsi.2013.11.005>>.

KOVÁCS, G.; HAJDU, A. A self-calibrating approach for the segmentation of retinal vessels by template matching and contour reconstruction. *Medical Image Analysis*, v. 29, p. 24 – 46, 2016. ISSN 1361-8415. doi:<<http://dx.doi.org/10.1016/j.media.2015.12.003>>.

KUMAR, K.; RANI, B.; KHAN, H.; RAVI, T. Detection of Retinal Diseases by Tracing Vessel Trees and Accurately Segmenting Vessels. *International Journal of Engineering*, n. 4, p. 182–187, 2012.

LAM, B. S. Y.; GAO, Y.; MEMBER, S.; LIEW, A. W.-c. General Retinal Vessel Segmentation Using Regularization-Based Multiconcavity Modeling. *IEEE Trans. on Medical Imaging*, v. 29, n. c, p. 1369–1381, 2010. doi:<<http://dx.doi.org/10.1109/TMI.2010.2043259>>.

LI, H.; CHUTATAPE, O. Boundary detection of optic disk by a modified ASM method. *Pattern Recognition*, v. 36, n. 9, p. 2093–2104, 2003. ISSN 00313203. doi:<[http://dx.doi.org/10.1016/S0031-3203\(03\)00052-9](http://dx.doi.org/10.1016/S0031-3203(03)00052-9)>.

LISKOWSKI, P.; KRAWIEC, K. Segmenting Retinal Blood Vessels with Deep Neural Networks. *IEEE Transactions on Medical Imaging*, v. 35, n. 11, p. 2369–2380, 2016. ISSN 1558254X. doi:<<http://dx.doi.org/10.1109/TMI.2016.2546227>>.

LU, S. Accurate and efficient optic disc detection and segmentation by a circular transformation. *IEEE Transactions on Medical Imaging*, v. 30, n. 12, p. 2126–2133, Dec 2011. ISSN 0278-0062. doi:<<http://dx.doi.org/10.1109/TMI.2011.2164261>>.

LUPAȘCU, C.; TEGOLO, D.; TRUCCO, E. Fabc: Retinal vessel segmentation using adaboost. *IEEE Transactions on Information Technology in Biomedicine*, v. 14, n. 5, p. 1267–1274, 2010. doi:<<http://dx.doi.org/10.1109/TITB.2010.2052282>>.

LYSTAD, L. D.; HAYDEN, B. C.; SINGH, A. D. Optic Nerve Disorders. *Ultrasound Clinics*, v. 3, n. 2, p. 257–266, 2008. ISSN 1556858X. doi:<<http://dx.doi.org/10.1016/j.cult.2008.04.010>>.

MA, J.; FAN, X.; YANG, S. X.; ZHANG, X.; ZHU, X. Contrast Limited Adaptive Histogram Equalization Based Fusion for Underwater Image Enhancement. *Preprints*, n. March, p. 1–27, 2017. doi:<<http://dx.doi.org/10.20944/preprints201703.0086.v1>>.

MAJI, D.; SANTARA, A.; MITRA, P.; SHEET, D. Ensemble of Deep Convolutional Neural Networks for Learning to Detect Retinal Vessels in Fundus Images. mar 2016.

MALEK, J.; ABDALLAH, M. B.; MANSOUR, A.; TOURKI, R. Automated optic disc detection in retinal images by applying region-based active aontour model in a variational level set formulation. In: *Computer Vision in Remote Sensing (CVRS), 2012 International Conference on*. [S.l.: s.n.], 2012. p. 39–44. doi:<<http://dx.doi.org/10.1109/CVRS.2012.6421230>>.

MARIN, D.; AQUINO, A.; GEGUNDEZ-ARIAS, M. E.; BRAVO, J. M. A new supervised method for blood vessel segmentation in retinal images by using gray-level and moment invariants-based features. *IEEE Transactions on Medical Imaging*, v. 30, n. 1, p. 146–158, Jan 2011. ISSN 0278-0062. doi:<<http://dx.doi.org/10.1109/TMI.2010.2064333>>.

MARIN, D.; GEGUNDEZ-ARIAS, M. E.; SUERO, A.; BRAVO, J. M. Obtaining optic disc center and pixel region by automatic thresholding methods on morphologically processed fundus images. *Computer Methods and Programs in Biomedicine*, v. 118, n. 2, p. 173–185, 2015. ISSN 0169-2607. doi:<<http://dx.doi.org/10.1016/j.cmpb.2014.11.003>>.

MARTIN, D.; FOWLKES, C.; TAL, D.; MALIK, J. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics. In: *Proc. 8th Int'l Conf. Computer Vision*. [s.n.], 2001. v. 2, p. 416–423. doi:<<https://doi.org/10.1109/iccv.2001.937655>>. Disponível em: <<http://www.eecs.berkeley.edu/Research/Projects/CS/vision/grouping/papers/mftm-iccv01.pdf>>.

MARTINEZ-PEREZ, M. E.; HUGHES, A. D.; THOM, S. A.; BHARATH, A. A.; PARKER, K. H. Segmentation of blood vessels from red-free and fluorescein retinal images. *Medical Image Analysis*, v. 11, n. 1, p. 47 – 61, 2007. ISSN 1361-8415. doi:<<http://dx.doi.org/10.1016/j.media.2006.11.004>>.

MARY, M. C. V. S.; RAJSINGH, E. B.; JACOB, J. K. K.; ANANDHI, D.; AMATO, U.; SELVAN, S. E. An empirical study on optic disc segmentation using an active contour model. *Biomedical Signal Processing and Control*, v. 18, p. 19–29, 2015. ISSN 1746-8094. doi:<<http://dx.doi.org/10.1016/j.bspc.2014.11.003>>.

MITTAPALLI, P. S.; KANDE, G. B. Segmentation of optic disk and optic cup from digital fundus images for the assessment of glaucoma. *Biomedical Signal Processing and Control*, v. 24, p. 34–46, 2016. ISSN 1746-8094. doi:<<http://dx.doi.org/10.1016/j.bspc.2015.09.003>>.

MOHABEY, A.; RAY, A. K. Rough set theory based segmentation of color images. In: *PeachFuzz 2000. 19th International Conference of the North American Fuzzy Information Processing Society - NAFIPS (Cat. No.00TH8500)*. [S.l.: s.n.], 2000. p. 338–342. ISBN 0780362748. doi:<<http://dx.doi.org/10.1109/NAFIPS.2000.877448>>.

MOOKIAH, M.; ACHARYA, U. R.; MARTIS, R. J.; CHUA, C. K.; LIM, C.; NG, E.; LAUDE, A. Evolutionary algorithm based classifier parameter tuning for automatic diabetic retinopathy grading: A hybrid feature extraction approach. *Knowledge-Based Systems*, v. 39, p. 9 – 22, 2013. ISSN 0950-7051. doi:<<http://dx.doi.org/10.1016/j.knosys.2012.09.008>>.

MOOKIAH, M. R.; ACHARYA, U. R.; CHUA, C. K.; MIN, L. C.; NG, E. Y.; MUSHRIF, M. M.; LAUDE, a. Automated detection of optic disk in retinal fundus images using intuitionistic fuzzy histon segmentation. *Proceedings of the Institution of Mechanical Engineers. Part H - Journal of Engineering in Medicine*, v. 227, n. 1, p. 37–49, 2013. doi:<<http://dx.doi.org/10.1177/0954411912458740>>.

MOOKIAH, M. R. K.; ACHARYA, U. R.; CHUA, C. K.; LIM, C. M.; NG, E.; LAUDE, A. Computer-aided diagnosis of diabetic retinopathy: A review. *Computers in Biology and Medicine*, v. 43, n. 12, p. 2136–2155, 2013. ISSN 00104825. doi:<<http://dx.doi.org/10.1016/j.compbiomed.2013.10.007>>.

MOOKIAH, M. R. K.; ACHARYA, U. R.; CHUA, K. C.; MIN, L. C.; NG, E.; MUSHRIF, M. M.; LAUDE, A. Automated detection of optic disk in retinal fundus images using intuitionistic fuzzy histon segmentation. *Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine*, v. 227, n. 1, p. 37–49, 2012. ISSN 09544119. doi:<<http://dx.doi.org/10.1177/0954411912458740>>.

MORALES, S.; NARANJO, V.; ANGULO, J.; ALCANIZ, M. Automatic detection of optic disc based on pca and mathematical morphology. *IEEE Transactions on Medical Imaging*, v. 32, n. 4, p. 786–796, April 2013. ISSN 0278-0062. doi:<<http://dx.doi.org/10.1109/TMI.2013.2238244>>.

MURAMATSU, C.; HATANAKA, Y.; IWASE, T.; HARA, T.; FUJITA, H. Automated selection of major arteries and veins for measurement of arteriolar-to-venular diameter ratio on retinal fundus images. *Computerized Medical Imaging and Graphics*, Elsevier Ltd, v. 35, n. 6, p. 472–480, 2011. ISSN 08956111. doi:<<http://dx.doi.org/10.1016/j.compmedimag.2011.03.002>>.

MURAMATSU, C.; NAKAGAWA, T.; SAWADA, A.; HATANAKA, Y.; HARA, T.; YAMAMOTO, T.; FUJITA, H. Automated segmentation of optic disc region on retinal fundus photographs: Comparison of contour modeling and pixel classification methods. *Computer Methods and Programs in Biomedicine*, v. 101, n. 1, p. 23–32, 2011. ISSN 0169-2607. doi:<<http://dx.doi.org/10.1016/j.cmpb.2010.04.006>>.

MUSHRIF, M. M.; RAY, A. K. Color image segmentation: Rough-set theoretic approach. *Pattern Recognition Letters*, v. 29, n. 4, p. 483–493, 2008. ISSN 01678655. doi:<<http://dx.doi.org/10.1016/j.patrec.2007.10.026>>.

MUSHRIF, M. M.; RAY, A. K. A-ifs histon based multithresholding algorithm for color image segmentation. *IEEE Signal Processing Letters*, v. 16, n. 3, p. 168–171, 2009. doi:<<https://doi.org/10.1109/lsp.2008.2010820>>.

MUSHRIF, M. M.; RAY, A. K. Rough fuzzy image analysis: Foundations and methodologies. In: _____. 1. ed. Boca Raton, FL, USA: CRC Press, Inc., 2010. cap. Image Segmentation: A Rough-set Theoretic Approach. doi:<<https://doi.org/10.1201/9781439803301>>.

NAYEBIFAR, B.; MOGHADDAM, H. A. A novel method for retinal vessel tracking using particle filters. *Computers in Biology and Medicine*, v. 43, n. 5, p. 541 – 548, 2013. ISSN 0010-4825. doi:<<http://dx.doi.org/10.1016/j.compbiomed.2013.01.016>>.

NEKOVEI, R.; SUN, Y. Classification of digital angiograms using artificial neural networks. In: *Engineering in Medicine and Biology Society*. [S.l.]: Proceedings of the Annual International Conference of the IEEE, 1991. v. 13, p. 1440–1441. doi:<<http://dx.doi.org/10.1109/IEMBS.1991.684536>>.

NEKOVEI, R.; SUN, Y. Back-propagation network and its configuration for blood vessel detection in angiograms. *IEEE Transactions on Neural Networks*, v. 6, n. 1, p. 64–72, 1995. ISSN 19410093. doi:<<http://dx.doi.org/10.1109/72.363449>>.

NGUYEN, U. T.; BHUIYAN, A.; PARK, L. A.; RAMAMOCHANARAO, K. An effective retinal blood vessel segmentation method using multi-scale line detection. *Pattern Recognition*, v. 46, n. 3, p. 703 – 715, 2013. ISSN 0031-3203. doi:<<http://dx.doi.org/10.1016/j.patcog.2012.08.009>>.

NIEMEIJER, M.; ABRAMOFF, M. D.; GINNEKEN, B. van. Segmentation of the optic disc, macula and vascular arch in fundus photographs. *IEEE Transactions on Medical Imaging*, v. 26, n. 1, p. 116–127, Jan 2007. ISSN 0278-0062. doi:<<http://dx.doi.org/10.1109/TMI.2006.885336>>.

NIEMEIJER, M.; ABRAMOFF, M. D.; GINNEKEN, B. van. Fast detection of the optic disc and fovea in color fundus photographs. *Medical Image Analysis*, Elsevier B.V., v. 13, n. 6, p. 859–870, 2009. ISSN 13618415. doi:<<http://dx.doi.org/10.1016/j.media.2009.08.003>>.

NIEMEIJER, M.; STAAL, J.; GINNEKEN, B. van; LOOG, M.; ABRAMOFF, M. D. Comparative study of retinal vessel segmentation methods on a new publicly available database. In: . [S.l.: s.n.], 2004. v. 5370, p. 648–656. doi:<<http://dx.doi.org/10.1117/12.535349>>.

NOVO, J.; PENEDO, M. G.; SANTOS, J. Localisation of the optic disc by means of GA-optimised Topological Active Nets. *Image and Vision Computing*, Elsevier B.V., v. 27, n. 10, p. 1572–1584, 2009. ISSN 02628856. doi:<<http://dx.doi.org/10.1016/j.imavis.2009.02.011>>.

- ORLANDO, J. I.; BLASCHKO, M. Learning fully-connected CRFs for blood vessel segmentation in retinal images. p. 634–41, sep 2014. doi:<https://doi.org/10.1007/978-3-319-10404-1_79>.
- OSAREH, A.; SHADGAR, B. Automatic blood vessel segmentation in color images of retina. *Iranian Journal of Science and Technology, Transaction B: Engineering*, v. 33, n. 2, p. 191–206, 2009. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-67749133713&partnerID=40&md5=81ba9c73642ef88302d8d3c848eeda9>>.
- PAL, S. K.; PETERS, J. F. *Rough Fuzzy Image Analysis: Foundations and Methodologies*. 1st. ed. Boca Raton, FL, USA: CRC Press, Inc., 2010. doi:<<https://doi.org/10.1201/9781439803301>>. ISBN 1439803293, 9781439803295.
- PAWLAK, Z. Rough sets. *International Journal of Computer and Information Sciences*, v. 11, n. 5, p. 341–356, 1982.
- PAWLAK, Z. *Rough Sets: Theoretical Aspects of Reasoning about Data*. Springer Netherlands, 1991. (Theory and Decision Library D:). ISBN 9780792314721. Disponível em: <<https://books.google.ie/books?id=MJPLCqIniGsC>>.
- PAWLAK, Z.; GRZYMALA-BUSSE, J.; SLOWINSKI, R.; ZIARKO, W. Rough sets. *Communication of the ACM*, v. 38, n. 11, p. 89–95, 1995. Disponível em: <<http://link.springer.com/article/10.1007/BF01001956>>.
- PEDRINI, H.; SCHWARTZ, W. R. *Análise de imagens digitais: princípios, algoritmos e aplicações*. THOMSON PIONEIRA, 2007. ISBN 9788522105953. Disponível em: <<https://books.google.com.br/books?id=13KAPgAACAAJ>>.
- PINÃO, J. M. N. *Fovea and Optic Disk Detection and Key Performance Indicators Process Automation*. Tese (Doutorado) — University of Coimbra, 2011. Disponível em: <<https://estudogeral.sib.uc.pt/handle/10316/17637>>.
- PIZER, S. M.; AMBURN, E. P.; AUSTIN, J. D.; CROMARTIE, R.; GESELOWITZ, A.; GREER, T.; ter Haar Romeny, B.; ZIMMERMAN, J. B.; ZUIDERVELD, K. Adaptive Histogram Equalization and Its Variations. *Computer vision, graphics, and image processing*, v. 39, n. 3, p. 355–368, 1987. ISSN 0734189X. doi:<[http://dx.doi.org/10.1016/S0734-189X\(87\)80186-X](http://dx.doi.org/10.1016/S0734-189X(87)80186-X)>.
- PREWITT, J. *Object enhancement and extraction*. 1970. 15–19 p.
- PURUSHARTHI, S.; KURHADE, B. Identification of Diabetic Retinopathy in Retinal Images using Support Vector Machine. *International Journal of Computing and Technology*, v. 1, n. 2, p. 158–167, 2014. Disponível em: <<http://www.ijcat.org/IJCAT-2014/1-2/Identification-of-Diabetic-Retinopathy-in-Retinal-Images-using-Support-Vector-Machine.pdf>>.
- QURESHI, R. J.; KOVACS, L.; HARANGI, B.; NAGY, B.; PETO, T.; HAJDU, A. Combining algorithms for automatic detection of optic disc and macula in fundus images. *Computer Vision and Image Understanding*, Elsevier Inc., v. 116, n. 1, p. 138–145, 2012. ISSN 10773142. doi:<<http://dx.doi.org/10.1016/j.cviu.2011.09.001>>.

- RABBANI, H.; ALLINGHAM, M. J.; METTU, P. S.; COUSINS, S. W.; FARSIU, S. Fully automatic segmentation of fluorescein leakage in subjects with diabetic macular edema. *Investigative Ophthalmology and Visual Science*, v. 56, n. 3, p. 1482–1492, 2015. ISSN 15525783. doi:<<http://dx.doi.org/10.1167/iovs.14-15457>>.
- RAMAKANTH, S. A.; BABU, R. V. Approximate Nearest Neighbour Field based Optic Disk Detection. *Computerized Medical Imaging and Graphics*, v. 38, n. 1, p. 49–56, 2014. ISSN 0895-6111. doi:<<http://dx.doi.org/10.1016/j.compmedimag.2013.10.007>>.
- RAO, P. V.; GAYATHRI, R.; SUNITHA, R. A Novel Approach for Design and Analysis of Diabetic Retinopathy Glaucoma Detection Using Cup to Disk Ratio and {ANN}. *Procedia Materials Science*, v. 10, p. 446–454, 2015. ISSN 2211-8128. doi:<<http://dx.doi.org/10.1016/j.mspro.2015.06.080>>.
- RICCI, E.; PERFETTI, R. Retinal blood vessel segmentation using line operators and support vector classification. *IEEE Transactions on Medical Imaging*, v. 26, n. 10, p. 1357–1365, Oct 2007. ISSN 0278-0062. doi:<<http://dx.doi.org/10.1109/TMI.2007.898551>>.
- RIVEST-HENAULT, D.; CHERIET, M.; DESCHENES, S.; LAPIERRE, C. Length increasing active contour for the segmentation of small blood vessels. In: *Pattern Recognition (ICPR), 2010 20th International Conference on*. [S.l.: s.n.], 2010. p. 2796–2799. ISSN 1051-4651. doi:<<http://dx.doi.org/10.1109/ICPR.2010.685>>.
- RODRÍGUEZ, R.; ALARCÓN, T. E.; PACHECO, O. A new strategy to obtain robust markers for blood vessels segmentation by using the watersheds method. *Computers in Biology and Medicine*, v. 35, n. 8, p. 665 – 686, 2005. ISSN 0010-4825. doi:<<http://dx.doi.org/10.1016/j.combiomed.2004.06.003>>.
- RODRÍGUEZ, R.; CASTILLO, P. J.; GUERRA, V.; AZUELA, J. H. S.; SUÁREZA, A. G.; IZQUIERDO, E. A comparison between two robust techniques for segmentation of blood vessels. *Computers in Biology and Medicine*, v. 38, n. 8, p. 931 – 940, 2008. ISSN 0010-4825. doi:<<http://dx.doi.org/10.1016/j.combiomed.2008.06.002>>.
- ROYCHOWDHURY, S.; KOOZEKANANI, D. D.; KUCHINKA, S. N.; PARHI, K. K. Optic disc boundary and vessel origin segmentation of fundus images. *IEEE Journal of Biomedical and Health Informatics*, v. 20, n. 6, p. 1562–1574, 2016. ISSN 21682194. doi:<<http://dx.doi.org/10.1109/JBHI.2015.2473159>>.
- SANTOS, C. de F. dos. *Uso de Saliências do Contorno via Esqueletização para Recuperação de Imagens*. Dissertação (Mestrado) — Universidade Federal de Uberlândia, Uberlândia, Janeiro 2007. Disponível em: <<http://repositorio.ufu.br/handle/123456789/12597>>.
- SARATHI, M. P.; DUTTA, M. K.; SINGH, A.; TRAVIESO, C. M. Blood vessel inpainting based technique for efficient localization and segmentation of optic disc in digital fundus images. *Biomedical Signal Processing and Control*, v. 25, p. 108 – 117, 2016. ISSN 1746-8094. doi:<<http://dx.doi.org/10.1016/j.bspc.2015.10.012>>.
- SEKHAR, S.; AL-NUAIMY, W.; NANDI, A. K. Automated localisation of retinal optic disk using hough transform. In: *2008 5th IEEE International Symposium on Biomedical Imaging: From Nano to Macro*. [S.l.: s.n.], 2008. p. 1577–1580. ISSN 1945-7928. doi:<<http://dx.doi.org/10.1109/ISBI.2008.4541312>>.

- SILVA, N. R. da. *Identificação de trajetórias espaço-temporais de movimentos em vídeo*. Dissertação (Mestrado) — Universidade Federal de Uberlândia, Uberlândia, Maio 2010. Disponível em: <<https://repositorio.ufu.br/handle/123456789/12502>>.
- SINGH, N. P.; SRIVASTAVA, R. Retinal blood vessels segmentation by using gumbel probability distribution function based matched filter. *Computer Methods and Programs in Biomedicine*, v. 129, p. 40 – 50, 2016. ISSN 0169-2607. doi:<<http://dx.doi.org/10.1016/j.cmpb.2016.03.001>>.
- SINTHANAYOTHIN, C.; BOYCE, J.; COOK, H.; WILLIAMSON, T. Automated localisation of the optic disc, fovea, and retinal blood vessels from digital colour fundus images. *British Journal of Ophthalmology*, v. 83, n. 8, p. 902–910, 1999. doi:<<https://doi.org/10.1136/bjo.83.8.902>>.
- SOARES, J. V. B.; LEANDRO, J. J. G.; CESAR, R. M.; JELINEK, H. F.; CREE, M. J. Retinal vessel segmentation using the 2-d gabor wavelet and supervised classification. *IEEE Transactions on Medical Imaging*, v. 25, n. 9, p. 1214–1222, Sept 2006. ISSN 0278-0062. doi:<<http://dx.doi.org/10.1109/TMI.2006.879967>>.
- SOMAN, K.; RAVI, D. Detection of exudates in human fundus image with a comparative study on methods for the optic disk detection. In: *Information Communication and Embedded Systems (ICICES), 2014 International Conference on*. [S.l.: s.n.], 2014. p. 1–5. doi:<<http://dx.doi.org/10.1109/ICICES.2014.7034010>>.
- SOOMRO, T. A.; AFIFI, A. J.; GAO, J.; HELLWICH, O.; KHAN, M. A. U.; PAUL, M.; ZHENG, L. Boosting sensitivity of a retinal vessel segmentation algorithm. *Pattern Analysis and Applications*, 2017. ISSN 14337541. doi:<<http://dx.doi.org/10.1007/s10044-017-0661-4>>.
- SREEJINI, K.; GOVINDAN, V. Improved multiscale matched filter for retina vessel segmentation using {PSO} algorithm. *Egyptian Informatics Journal*, v. 16, n. 3, p. 253 – 260, 2015. ISSN 1110-8665. doi:<<http://dx.doi.org/10.1016/j.eij.2015.06.004>>.
- STAAL, J.; ABRAMOFF, M.; NIEMEIJER, M.; VIERGEVER, M.; GINNEKEN, B. van. Ridge based vessel segmentation in color images of the retina. *IEEE Transactions on Medical Imaging*, v. 23, n. 4, p. 501–509, 2004. doi: <<https://doi.org/10.1109/tmi.2004.825627>>. Disponível em: <<http://www.isi.uu.nl/Research/Databases/DRIVE/>>.
- SUERO, A.; MARIN, D.; GEGUNDEZ-ARIAS, M. E.; BRAVO, J. M. Locating the Optic Disc in Retinal Images Using Morphological Techniques. *Iwbbio*, p. 18–20, 2013. Disponível em: <<https://pdfs.semanticscholar.org/8227/421bdd762782672a3cdbca394bd59415d3dd.pdf>>.
- SUM, K. W.; CHEUNG, P. Y. S. Vessel extraction under non-uniform illumination: A level set approach. *IEEE Transactions on Biomedical Engineering*, v. 55, n. 1, p. 358–360, Jan 2008. ISSN 0018-9294. doi:<<http://dx.doi.org/10.1109/TBME.2007.896587>>.
- TOBIN, K. W.; CHAUM, E.; GOVINDASAMY, V. P.; KARNOWSKI, T. P. Detection of anatomic structures in human retinal imagery. *IEEE Transactions on Medical Imaging*, v. 26, n. 12, p. 1729–1739, 2007. ISSN 02780062. doi:<<http://dx.doi.org/10.1109/TMI.2007.902801>>.
- TSAI, Y.-C.; LEE, H.-J.; CHEN, M. Y.-C. Automatic segmentation of vessels from angiogram sequences using adaptive feature transformation. *Computers in Biology and Medicine*, v. 62, p. 239 – 253, 2015. ISSN 0010-4825. doi:<<http://dx.doi.org/10.1016/j.combiomed.2015.04.029>>.

- VEGA, R.; SANCHEZ-ANTE, G.; FALCON-MORALES, L. E.; SOSSA, H.; GUEVARA, E. Retinal vessel extraction using lattice neural networks with dendritic processing. *Computers in Biology and Medicine*, v. 58, p. 20 – 30, 2015. ISSN 0010-4825. doi:<<http://dx.doi.org/10.1016/j.compbiomed.2014.12.016>>.
- VELHO, L.; FRERY, A. C.; GOMES, J. *Image Processing for Computer Graphics and Vision*. 2. ed. London: Springer, 2009. doi:<https://doi.org/10.1007/978-1-84800-193-0_1>.
- VILIS, T. *The Visual Cortex Contents*. London, Ontário - Canadá: University of Western Ontario, Department of Physiology and Pharmacology, 2013. 0–16 p. Disponível em: <www.tutis.ca/NeuroMD/index.htm>.
- VLACHOS, I. K.; SERGIADIS, G. D. Intuitionistic fuzzy image processing. *Studies in Fuzziness and Soft Computing*, v. 210, n. 2002, p. 383–414, 2007. doi:<https://doi.org/10.1007/978-3-540-38233-1_14>.
- VLACHOS, M.; DERMATAS, E. Multi-scale retinal vessel segmentation using line tracking. *Computerized Medical Imaging and Graphics*, v. 34, n. 3, p. 213 – 227, 2010. ISSN 0895-6111. doi:<<http://dx.doi.org/10.1016/j.compmedimag.2009.09.006>>.
- WANG, L.; BHALERAO, A.; WILSON, R. Analysis of retinal vasculature using a multiresolution hermite-gaussian model. *IEEE Trans. on Medical Imaging*, v. 26, n. 2, p. 17, 2007. doi:<<http://dx.doi.org/10.1109/TMI.2006.889732>>. Disponível em: <<http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=4077864&newsearch=true&queryText=bhalerao>>.
- WANG, S.; YIN, Y.; CAO, G.; WEI, B.; ZHENG, Y.; YANG, G. Hierarchical retinal blood vessel segmentation based on feature and ensemble learning. *Neurocomputing*, v. 149, Part B, p. 708 – 717, 2015. ISSN 0925-2312. doi:<<http://dx.doi.org/10.1016/j.neucom.2014.07.059>>.
- WANG, Y.; JI, G.; LIN, P.; TRUCCO, E. Retinal vessel segmentation using multiwavelet kernels and multiscale hierarchical decomposition. *Pattern Recognition*, v. 46, n. 8, p. 2117 – 2133, 2013. ISSN 0031-3203. doi:<<http://dx.doi.org/10.1016/j.patcog.2012.12.014>>.
- WHO, W. H. O. *Global Data on Visual Impairments 2010*. [S.l.], 2010. 17 p. Disponível em: <<http://www.who.int/blindness/GLOBALDATAFINALforweb.pdf>>.
- WHO, W. H. O. *Global initiative for the elimination of avoidable blindness: action plan 2006-2011*. [S.l.], 2012. Disponível em: <http://www.who.int/blindness/Vision2020{_}report.pdf?u>.
- WHO, W. H. O. *Cegueira y discapacidad visual*. 2014. 17 p. Acessado em junho de 2015. Disponível em: <<http://www.who.int/mediacentre/factsheets/fs282/es/>>.
- XIE, C.-H.; LIU, Y.-J.; CHANG, J.-Y. Medical image segmentation using rough set and local polynomial regression. *Multimedia Tools and Applications*, v. 74, n. 6, p. 1885–1914, 2015. ISSN 1380-7501. doi:<<http://dx.doi.org/10.1007/s11042-013-1723-2>>.
- XU, L.; LUO, S. A novel method for blood vessel detection from retinal images. *BioMedical Engineering OnLine*, v. 9, n. 1, p. 1–10, 2010. ISSN 1475-925X. doi:<<http://dx.doi.org/10.1186/1475-925X-9-14>>.
- YANG, X.; HAMAGUCHI, S.; SUN, Y.; XIAO, S. Detect of optic disc center based on gaussian vessel detector and tangent information transform. In: *2011 4th International Conference on Biomedical Engineering and Informatics (BMEI)*. [S.l.: s.n.], 2011. v. 1, p. 250–254. ISSN 1948-2914. doi:<<http://dx.doi.org/10.1109/BMEI.2011.6098325>>.

YOU, X.; PENG, Q.; YUAN, Y.; CHEUNG, Y. ming; LEI, J. Segmentation of retinal blood vessels using the radial projection and semi-supervised approach. *Pattern Recognition*, v. 44, n. 10–11, p. 2314 – 2324, 2011. ISSN 0031-3203. doi:<<http://dx.doi.org/10.1016/j.patcog.2011.01.007>>.

YOUSSEF, A. A. H. A. R.; GHALWASH, A. Z.; GHONEIM, A. A. S. A. R. Optic disc detection from normalized digital fundus images by means of a vessels' direction matched filter. *IEEE Transactions on Medical Imaging*, v. 27, n. 1, p. 11–18, 2008. ISSN 02780062. doi:<<http://dx.doi.org/10.1109/TMI.2007.900326>>.

YU, H.; BARRIGA, E. S.; AGURTO, C.; ECHEGARAY, S.; PATTICHIS, M. S.; BAUMAN, W.; SOLIZ, P. Fast localization and segmentation of optic disk in retinal images using directional matched filtering and level sets. *IEEE Transactions on Information Technology in Biomedicine*, v. 16, n. 4, p. 644–657, July 2012. ISSN 1089-7771. doi:<<http://dx.doi.org/10.1109/TITB.2012.2198668>>.

ZAKI, W. M. D. W.; ZULKIFLEY, M. A.; HUSSAIN, A.; HALIM, W. H. W. A.; MUSTAFA, N. B. A.; TING, L. S. Diabetic retinopathy assessment: Towards an automated system. *Biomedical Signal Processing and Control*, Elsevier Ltd, v. 24, p. 72–82, 2016. ISSN 17468108. doi:<<http://dx.doi.org/10.1016/j.bspc.2015.09.011>>.

ZANA, F.; KLEIN, J. C. Segmentation of vessel-like patterns using mathematical morphology and curvature evaluation. *IEEE Transactions on Image Processing*, v. 10, n. 7, p. 1010–1019, 2001. ISSN 10577149. doi:<<http://dx.doi.org/10.1109/83.931095>>.

ZHANG, L.; FISHER, M.; WANG, W. Retinal vessel segmentation using multi-scale textons derived from keypoints. *Computerized Medical Imaging and Graphics*, v. 45, p. 47 – 56, 2015. ISSN 0895-6111. doi:<<http://dx.doi.org/10.1016/j.compmedimag.2015.07.006>>.

ZHAO, Y. Q.; WANG, X. H.; WANG, X. F.; SHIH, F. Y. Retinal vessels segmentation based on level set and region growing. *Pattern Recognition*, v. 47, n. 7, p. 2437 – 2446, 2014. ISSN 0031-3203. doi:<<http://dx.doi.org/10.1016/j.patcog.2014.01.006>>.

ZHU, X.; RANGAYYAN, R. M.; ELLS, A. L. Detection of the optic nerve head in fundus images of the retina using the hough transform for circles. *Journal of Digital Imaging*, v. 23, n. 3, p. 332–341, 2010. ISSN 08971889. doi:<<http://dx.doi.org/10.1007/s10278-009-9189-5>>.


APÊNDICE A

IMAGENS E MODELOS DE CORES


Geralmente, as técnicas de processamento de imagens são aplicadas sobre as imagens em sua forma de matriz, algumas delas são voltadas para escala de cinza e outras para imagens coloridas, quando é este o caso, uma decisão importante na implementação da técnica é a respeito do esquema de cores a ser utilizado. Os modelos de cores (ou espaços de cores), facilitam a especificação das cores ao tratá-las como combinação de outras, tal qual o sistema visual humano que possui cones sensíveis a comprimentos de onda correspondentes às três cores primárias. Nessa formulação, cada cor pode ser representada como um único ponto em um subespaço dentro do modelo em uso e cada eixo do subespaço reflete uma tonalidade ou propriedade do espaço de cores (GONZALEZ; WOODS, 2010, 264).

Existem diversos modelos em uso atualmente, os principais são o RGB (*Red, Green, Blue* – vermelho, verde, azul) , o CMYK (*Cyan, Magenta, Yellow, Black* – ciano, magenta, amarelo, preto) e o HSI (*Hue, Saturation, Intensity* – matiz, saturação, intensidade) . A Figura A.1 mostra o modelo RGB e o modelo CMYK, o primeiro é baseado em cores primárias em um formato aditivo, conforme a Figura A.1(c), uma imagem colorida RGB é obtida a partir da sobreposição das matrizes de intensidade vermelha, verde e azul. Já o modelo CMYK possui formato subtrativo e usa cores secundárias, neste modelo uma cor absorve uma cor primária e reflete as outras duas.

A Figura A.2 sintetiza as aplicações destes dois modelos bem como as cores contempladas pelo subespaço, é possível perceber que nenhum destes dois, seja em impressões ou exibição em monitor é capaz de cobrir todo o espectro visível. Pode-se observar também que o subespaço RGB é um padrão em hardware e processamento por meio de software, CMYK é utilizado para impressão colorida.

Figura A.1: Modelos de cores.

(a) cores RGB. (b) cores CMYK. (c) Sobreposição das matrizes de intensidade para gerar modelo de cores RGB.

Figura A.2: Modelos de cores e dispositivos

(a) Subespaço de cores correspondente ao espectro visível determinado pelo CIE 1976. (b) Subespaços RGB e CMYK em relação ao espectro visível. (c) Relação de dispositivos de entrada e saída com os modelos de cores. **Fonte:** blog corisectelmo - Disponível em <<http://corisectelmo.blogspot.com.br/2011/01/aula-21-espaco-de-cor-lab.html>> acessado em ago. 2015.


O modelo HSI é mostrado na Figura A.3, ele é mais utilizado em técnicas de processamento de imagens coloridas, pois algumas técnicas tiram vantagem da maneira como ele decompõe a informação de cor. A Figura A.3(b) mostra a matiz, o vermelho fica próximo ao preto, uma vez que as cores são transformadas a partir do vermelho até chegar ao azul, que está mais claro. A Figura A.3(c) mostra a saturação, sendo que as cores primárias são completamente saturadas. A Figura A.3(d) mostra a intensidade.

Embora os modelos de cores sejam fáceis de manipular e propiciem boas representações, eles não são exatos pois dispositivos podem representar de maneira diferente uma certa cor. Assim, deve haver um mapeamento do modelo de cor para um modelo independente de dispositivo (GONZALEZ; WOODS, 2010).

Ao contrário dos modelos de cores, CIE Lab é um esquema de cores independente proposto pela *Comission Internationale de l'Eclairage* – Comissão Internacional de Iluminação (CIE) em 1976 com o objetivo de padronizar e reproduzir com fidelidade as cores do espectro visível, embora não possa ser utilizado para exibição direta, é capaz de representar com exatidão qualquer cor do espectro visível. Trata-se um esquema subtrativo composto por um canal de luminância e dois de cromaticidade, pode ser usado para representar cores para exibição, impressão e entrada. No modelo em questão, a luminância é substituída pela intensidade luminosa e varia de 0 (preto) a 100 (branco) e os canais de cromaticidade são **a** (vai do verde ao vermelho) e **b** (vai do azul ao amarelo).

No presente trabalho, é utilizado o modelo de cor RGB, que por vezes é transformado em CIE Lab, afim de aplicar correções de iluminação e remoção de ruído, dentre outros. A transformação do modelo RGB em CIE Lab é obtido por meio das equações, (GONZALEZ; WOODS, 2010):

Figura A.3: Modelo de cores HSI



(a) Cores RGB. (b) Matiz. (c) Saturação. (d) Intensidade.

$$L = 116 \cdot h\left(\frac{Y}{Y_W}\right) - 16 \quad (\text{A.1})$$

$$a = 500 \left[\left(\frac{X}{X_W}\right) - h\left(\frac{Y}{Y_W}\right) \right] \quad (\text{A.2})$$

$$b = 200 \left[h\left(\frac{Y}{Y_W}\right) - h\left(\frac{Z}{Z_W}\right) \right] \quad (\text{A.3})$$

sendo

$$h(q) = \begin{cases} \sqrt[3]{q} & q > 0,008856 \\ 7,787q + 16/116 & q \leq 0,008856 \end{cases} \quad (\text{A.4})$$

Em que X_W , Y_W e Z_W são valores de referência do triestímulo¹ branco e X , Y e Z representam as intensidades em cada canal.

¹Os valores do triestímulo branco são determinados por meio de um difusor de reflexão perfeita, no padrão CIE D65 são utilizados os valores $x = 0,3127$ e $y = 0,3290$, resultando em $X_W = 95.13$, $Y_W = 100.0$ e $Z_W = 108.86$.

APÊNDICE B


GLAUCOMA E RETINOPATIA DIABÉTICA

Duas das principais doenças que acometem o fundo de olho são o glaucoma e a retinopatia diabética. A seguir são apresentadas informações sobre essas duas doenças.

B.1 Glaucoma

O Glaucoma é uma doença silenciosa, dificilmente causa sintomas até que a perda visual seja grande e definitiva. Existe dois tipos de Glaucoma, o de ângulo aberto e o de ângulo fechado, o glaucoma de ângulo fechado geralmente ocorre de forma intempestiva devido a uma curvatura acentuada na córnea, enquanto que o glaucoma de ângulo aberto costuma se desenvolver em um processo lento em que há o aumento da pressão do olho devido ao acúmulo de humor vítreo, e consequente pressionamento na cabeça do nervo óptico, localizado no fundo do olho, ocasionando a perda de fibras nervosas e escavação do nervo. A Figura B.1 mostra um disco óptico glaucomatoso (DORION, 2002).

O nervo óptico possui uma escavação fisiológica que até certo ponto é considerada normal, caso essa escavação se torne grande em relação ao diâmetro do nervo óptico, há grandes chances que o glaucoma tenha se estabelecido. Há que se destacar que apenas uma escavação acentuada não fecha o diagnóstico de glaucoma (BUDAI et al., 2013b). Para efeitos de triagem do glaucoma, adota-se a proporção escavação/disco (E/D) de 0,6 ou assimetria de escavação maior 0,2 entre os olhos. Quanto ao formato, a escavação pode ser redonda, oval ou excêntrica e pode se expandir para fora do disco óptico, principalmente em sentido nasal (DORION, 2002).

Figura B.1: Recorte de Disco óptico (D) contendo escavação (E)

Fonte: base HRF (BUDAI et al., 2013b).

B.2 Retinopatia diabética

Diabetes *Mellitus* é uma doença devastadora, além de afetar diversos órgãos e comprometer a qualidade de vida do doente, pode causar lesões na retina ocasionando uma doença chamada retinopatia diabética - Diabetic Retinopathy (DR). A retinopatia diabética é caracterizada pela presença de microaneurismas, conforme (DORION, 2002, p.137), estes nada mais são que pequenas protrusões das paredes de vasos capilares, geralmente ocasionadas por neovascularização. A Figura B.2 mostra um caso de retinopatia diabética, extraído da base HRF (BUDAI et al., 2013b), em que se nota diversos microaneurismas, manchas algodinosas e alguns exsudatos duros.

A neovascularização está presente quando novos vasos se desenvolvem em algum lugar na retina (exceto no disco óptico) e produz como sintoma a visão turva, distorção¹ e pontos difusos. A retinopatia diabética não é a única que causa este problema, a retinopatia da prematuridade (ROP), anemia da célula falciforme, hemoglobinopatias, beta-talassemia, doença de Eales, síndromes de hiperviscosidade, leucemia, degeneração macular disciforme, vitreoretinopatia familiar exsudativa, toxoplasmose, sarcoidose, histoplasmose, miopia, estrias angioides, melanoma coróide, ruptura coróide, toxemia da gravidez, esclerose múltipla, e também em algumas condições como o uso de drogas IV, ou a complicação de fotocoagulação a laser e ainda fatores angiogênicos também causam neovascularização (DORION, 2002).

Na retinopatia diabética, assim como em outras retinopatias, a neovascularização pode ocorrer na superfície da retina, abaixo da retina ou na coróide, e quando é este último caso é dito que o paciente desenvolveu a *Proliferative Diabetic Retinopathy*(PDR) - retinopatia diabética proliferativa, nos dois casos anteriores tem-se a *No Proliferative Diabetic Retinopathy*(NPDR)

¹As extremidades ou as linhas retas aparecem distorcidas

Figura B.2: Retinopatia diabética não proliferativa.

Fonte: HRF (BUDAI et al., 2013b).

Tabela B.1: Características da neovascularização (DORION, 2002)


Local da Neovascularização	Característica retiniana da neovascularização
Superfície da retina (NPDR)	é uma área achatada e composta por vasos finos com pontas dilatadas. As pontas são na forma sacular (esférica) e possuem calibre de duas a quatro vezes maiores que os vasos.
Sub-retiniana (NPDR)	localizada abaixo da retina, contém fluido seroso turvo, pigmento, e até o descolamento do epitélio pigmentar da retina (EPR).
Coróide (PDR)	Novos vasos abaixo do epitélio pigmentar da retina (EPR) erguem-se perto de uma veia e produzem uma área cinzenta com descoloração ou ainda uma membrana neovascular coróide – anel de pigmento.

- retinopatia diabética não proliferativa. A Tabela B.1 sintetiza as características de cada um destes tipos de neovascularização.

A DR evolui em diferentes estágios, inicialmente o paciente sequer possui alterações em sua qualidade visual, da mesma forma, a imagem de fundo de olho apresenta poucas alterações, com o tempo a neovascularização, os microaneurismas e hemorragias aumentam, surgem exsudatos e outros sinais, por isso, ao desenvolver a DR o paciente gradativamente terá pioras em sua visão, as vezes podem acontecer melhoras também, já que exsudatos e hemorragias podem ser absorvidas (HENDRICK et al., 2015). A Figura B.3 simula a visão de um portador de DR para perto e para longe. A Figura B.4 mostra a imagem de fundo de olho em diferentes estágios da doença.

Figura B.3: Alterações da visão na retinopatia diabética.

Fonte: Grupo de Estudos da Retina - GER².

Figura B.4: Estágios da retinopatia diabética.

(a) Retina normal. (b) NPDR leve. (c) NPDR moderada. (d) NPDR severa. (e) PDR. (f) Edema Macular.
Fonte: Mookiah et al. (2013c).

²Disponível em: <<http://www.ger-portugal.com/retrievedocumentos.aspx?id=53>> acessado em abr. 2016.