UNIVERSIDADE DE SÃO PAULO

FFCLRP – DEPARTAMENTO DE FÍSICA E MATEMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA APLICADA
À MEDICINA E BIOLOGIA

**Imagem tridimensional da deformação
da musculatura extraocular na orbitopatia
de Graves: implicações do efeito de volume parcial**

ANDRÉ DOMINGOS ARAÚJO SOUZA

Tese apresentada à Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto da USP, como parte das exigências para a obtenção do título de Doutor em Ciências, Área: Física Aplicada à Medicina e Biologia.

RIBEIRÃO PRETO – SP
2002

UNIVERSIDADE DE SÃO PAULO

FFCLRP – DEPARTAMENTO DE FÍSICA E MATEMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA APLICADA
À MEDICINA E BIOLOGIA

**Imagem tridimensional da deformação
da musculatura extraocular na orbitopatia
de Graves: implicações do efeito de volume parcial**

por **ANDRÉ DOMINGOS ARAÚJO SOUZA**

orientador **PROF. DR. EVANDRO EDUARDO SERON RUIZ**

Tese apresentada à Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto da USP, como parte das exigências para a obtenção do título de Doutor em Ciências, Área: Física Aplicada à Medicina e Biologia.

RIBEIRÃO PRETO – SP

2002

FICHA CATALOGRÁFICA

Preparada pela Biblioteca Central do Campus Administrativo
de Ribeirão Preto / USP.

Souza, André Domingos Araújo.

Imagem tridimensional da deformação da musculatura
extraocular na orbitopatia de Graves: implicações do efeito
de volume parcial. Ribeirão Preto, 2002.

102 p. : il. ; 30 cm

Tese de doutorado apresentada à Faculdade de Filosofia,
Ciências e Letras de Ribeirão Preto da USP – Área: Física
Aplicada à Medicina e Biologia.

Orientador: Ruiz, Evandro Eduardo Seron.

1. Visualização 3D, segmentação, músculos extraoculares.
2. Efeito de volume parcial, LoG, morfologia matemática.

Aos meus pais, Eulálio e Maria Lúcia, e à minha querida esposa, Maria Juciene.

“Pouco a pouco, a máquina se tornará parte da humanidade.”

Aviador e escritor francês Antoine de Saint-Exupéry, em 1939 no livro Terra dos Homens.

Agradecimentos

Meus agradecimentos especiais ao professor Evandro Ruiz pelo apoio não só científico, mas também pessoal durante o desenvolvimento do trabalho.

Ao professor Antonio Augusto Cruz pelas sugestões médicas e por disponibilizar as imagens de CT de órbitas utilizadas no trabalho.

Aos professores Roberto Lotufo e Alexandre Falcão pelo apoio e incentivo à minha ida ao *Image Processing Group (MIPG), University of Pennsylvania, Philadelphia*.

A todos do Departamento de Física e Matemática, USP – Ribeirão Preto: funcionários, alunos e professores que de alguma forma me ajudaram durante esses quatro anos.

Aos amigos do grupo ImagCom: Adriano Holanda, Ivan Pisa, Marcelo Santos, Sebastião Silva pela amizade, descontração e diálogos.

Aos colegas do MIPG: Avi Vardi, Ying Zhuge, Sumiaki Matsumoto, Tad Iwanaga, Jiamin Liu, Mary Blue, e ao professor Robert Lewitt pela assistência durante o meu estágio.

Meus sinceros agradecimentos aos Professores Jayaram Udupa e Punam Saha pela supervisão e incentivo durante o meu estágio no MIPG.

Aos amigos da UPenn que tornaram o período na Filadélfia muito agradável.

A Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pela bolsa de estudos concedida e pela valiosa assessoria científica.

Sumário

AGRADECIMENTOS	VII
SUMÁRIO	IX
LISTA DE FIGURAS	XI
LISTA DE TABELAS	XIII
LISTA DE ABREVIATURAS	XV
PUBLICAÇÕES ORIGINADAS DESTA TESE	XVII
RESUMO	XIX
CAPÍTULO 1	
INTRODUÇÃO	1
1.1 MOTIVAÇÃO E OBJETIVOS	1
1.2 MATERIAIS	2
1.3 ESTRUTURA DA TESE	3
CAPÍTULO 2	
CONCEITOS BÁSICOS	5
2.1 SEGMENTAÇÃO EM IMAGEM DIGITAL	5
2.2 VISUALIZAÇÃO VOLUMÉTRICA	10
2.2.1 <i>RENDENRING</i> SUPERFICIAL	15
2.2.2 <i>RENDERING</i> VOLUMÉTRICO	18
2.3 O EFEITO DE VOLUME PARCIAL	19
2.4 DEFORMAÇÃO DOS MÚSCULOS EXTRAOCULARES NA ORBITOPATIA DE GRAVES	20

CAPÍTULO 3

QUANTIFICAÇÃO DA MUSCULATURA

EXTRAOCULAR POR IMAGEM DIGITAL 25

3.1 INTRODUÇÃO 25

3.2 SEGMENTANDO OS MÚSCULOS EXTRAOCULARES 26

3.2.1 PRODUZINDO UMA MÁSCARA LOG ÓTIMA 26

3.2.2 O MÉTODO DE SEGMENTAÇÃO 32

3.3 A QUANTIFICAÇÃO 3D DA MUSCULATURA EXTRAOCULAR 39

3.4 RESULTADOS 43

CAPÍTULO 4

RENDERIZAÇÃO VOLUMÉTRICA

NA PRESENÇA DO EFEITO DE VOLUME PARCIAL 53

4.1 INTRODUÇÃO 53

4.2 CLASSIFICANDO VOXELS COM EFEITO DE VOLUME PARCIAL 55

4.2.1 O MÉTODO DE MEDIDA DE FRAÇÃO 58

4.2.2 O MÉTODO BASEADO NO PRINCÍPIO DA INCERTEZA 59

4.3 O MÉTODO PARA REMOÇÃO DA PELE 61

4.4 RESULTADOS 62

CAPÍTULO 5

CONCLUSÕES 75

6 ANEXOS COLORIDOS 79

7 REFERÊNCIAS BIBLIOGRÁFICAS 91

ABSTRACT 101

Lista de Figuras

Fig. 2.1. Processo de representação digital de uma imagem.	6
Fig. 2.2. Limiarização.	6
Fig. 2.3. A Função Gaussiana 2D e o respectivo Laplaciano da Gaussiana.	8
Fig. 2.4. Processo de visualização volumétrica para imagens médicas.	11
Fig. 2.5. Os cubóides representam os voxels em imagens médicas.	13
Fig. 2.6. Tipos de malhas.	14
Fig. 2.7. <i>Rendering</i> superficial por triangulação de contornos (a), e faces de voxels (b).	16
Fig. 2.8. <i>Marching cubes</i> : as configurações básicas para triangulação de uma única <i>célula</i>	17
Fig. 2.9. (a) Distribuição em tons de cinza dos diferentes tecidos. (b) Uma relação nebulosa (fuzzy) entre as transições dos diferentes tecidos. (c) Função de opacidade.	20
Fig. 2.10. Ilustração do efeito de volume parcial.	20
Fig. 2.11. Musculatura extraocular (adaptada do <i>Atlas visual</i> , ed. Ática, 1996).	21
Fig. 2.12. Imagem CT coronal da órbita de um paciente normal.	22
Fig. 2.13. Imagem CT coronal da órbita de um paciente com orbitopatia de Graves.	22
Fig. 3.1. Truncamento da função contínua LoG (secção transversal).	27
Fig. 3.2. Erro da energia no domínio espacial.	29
Fig. 3.3. Mapa de contornos de uma imagem CT coronal da órbita.	31
Fig. 3.4. Erro na detecção do <i>zero-crossing</i>	31
Fig. 3.5. Erro normalizado na detecção do <i>zero-crossing</i> para $\sigma > 2,0$	32
Fig. 3.6. Falhas na detecção dos EOM usando o <i>zero-crossing</i>	33
Fig. 3.7. A primeira solução para extração dos EOM.	33
Fig. 3.8. Diagrama de blocos da primeira solução para extração dos EOM.	34
Fig. 3.9. Elemento estruturante em forma de disco plano.	34
Fig. 3.10. Diagrama de blocos do MSEG.	35
Fig. 3.11. Elemento estruturante cruz.	36
Fig. 3.12. Sequência inicial da detecção da órbita.	36

Fig. 3.13. Seqüência final da detecção da órbita.....	37
Fig. 3.14. Ilustração da detecção dos EOM.....	38
Fig. 3.15. O Aplicativo.....	39
Fig. 3.16. Exemplo de um estudo dos EOM por CT.	40
Fig. 3.17. Algoritmo de SR.....	41
Fig. 3.18. Gráfico de correlação entre a segmentação manual e automática.	45
Fig. 3.19. Gráfico das distribuições das áreas dos EOM nos grupos – fator músculo.	46
Fig. 3.20. Gráfico das distribuições das áreas nos grupos – fator posição tomográfica coronal.	47
Fig. 3.21. Gráfico das distribuições do fator taxa de ocupação do EOM na órbita nos grupos.	48
Fig. 3.22 ^{cor} . Renderização superficial dos EOM e parte do crânio.....	49
Fig. 3.23. O erro nas medidas de volume e superfície nos modelos 3D de esferas devido à redução de triângulos.....	50
Fig. 3.24. Modelo 3D do globo ocular.	51
Fig. 4.1. Ilustrações das regiões afetadas pelo PVE numa fatia de um dado volumétrico CT da cabeça.....	54
Fig. 4.2 ^{cor} . VR da Fig. 4.1a mostrando a musculatura facial e o crânio.	55
Fig. 4.3. Ilustração da cena de escala.	57
Fig. 4.4. Funções Gaussianas W_r	59
Fig. 4.5. Ilustração das regiões de incerteza em bordas nebulosas numa fatia de CT da cabeça.	60
Fig. 4.6. Remoção dos voxels com PVE na fatia mostrada na Fig. 4.1.....	63
Fig. 4.7 ^{cor} . VR de CT num paciente com anomalia craniofacial.	64
Fig. 4.8 ^{cor} . VR de CT do joelho. Superior-esquerdo.....	65
Fig. 4.9 ^{cor} . VR de CT da cabeça da <i>visible woman</i>	66
Fig. 4.10. VR de CT do tronco.....	67
Fig. 4.11. SR de CT do joelho.	68
Fig. 4.12. SR de CT da cabeça da <i>visible woman</i>	69
Fig. 4.13. Fantom matemático 3D.....	70
Fig. 4.14 ^{cor} . VR dos fantons 3D.....	71
Fig. 4.15. Secção transversal das regiões de tecido mole mostrados na Fig. 4.14. ^{cor}	72

Lista de Tabelas

Tabela 2.1. Algoritmos de visualização volumétrica.	15
Tabela 3.1. Correlação R entre as áreas medidas manualmente e pelo MSEG.	44
Tabela 3.2. Diferenças estatisticamente significantes entre os grupos usando taxa de ocupação dos EOM na órbita TO.	48
Tabela 3.3. Erro devido à amostragem.	49
Tabela 3.4. Erro devido à redução de triângulos.	50
Tabela 3.5. Erro do volume num modelo 3D dos EOM.	51
Tabela 4.1. Descrição dos dados 3D.	62
Tabela 4.2. Média, desvio padrão (SD) e valores mínimos da FOM_x , sendo $x = \{FM,$ UP}.	73

Lista de Abreviaturas

CT	Tomografia computadorizada por raios-X.
2D	Bidimensional.
EOM	Músculos extraoculares.
Fig. x.x ^{cor}	Indica que a Fig. x.x é fornecida em cores no Anexo Colorido (p.79).
FM	MCLA utilizando a informação da fração.
FMRP-HC	Faculdade de Medicina de Ribeirão Preto, Hospital das Clínicas.
GO	Globo ocular.
LoG	Laplaciano da Gaussiana.
MCLA	Métodos de classificação dos voxels com PVE.
MH	Musculatura horizontal.
MRI	Imagem por ressonância magnética.
MSEG	Método de segmentação dos EOM.
MVI	Musculatura vertical inferior.
MVS	Musculatura vertical superior.
NO	Nervo óptico.
OSE	Algoritmo para estimar a escala do objeto.
PET	Tomografia por emissão de pósitron.
Pixel	Elemento de imagem.
PVE	Efeito de volume parcial.
RI	Reto inferior.
RL	Reto lateral
RM	Reto medial.
CS	Complexo superior formado pelo reto superior e o elevador da pálpebra.
ROI	Região de interesse.
SPECT	Tomografia por emissão de fóton.
SR	<i>Rendering</i> superficial.
TO	Taxa de ocupação muscular.

UP	MCLA utilizando a classe de incerteza baseada no tom de cinza da cena.
US	Ultra-sonografia.
3D	Tridimensional.
ViSC	Visualização científica.
Voxel	Elemento de volume.
VR	<i>Rendering</i> volumétrico.

Publicações Originadas desta Tese

1. Souza A.D.A., Udupa J.K., Saha P.K., Volume rendering in the presence of partial volume effects, *SPIE Proc: Medical Imaging 2002*, San Diego – California, February 23-28, 2002 (accepted).
2. Souza A.D.A., Ruiz E.E.S., Optimal filter based on the Laplacian of Gaussian associated to shape-analysis edge detection for orbit images, *LASTED International Conference on Signal and Image Processing (SIP'2000)*, Las Vegas – Nevada, November 20-23, 2000.
3. Souza A.D.A., Ruiz E.E.S., Fast and accurate detection of extraocular muscles borders using mathematical morphology, *Chicago 2000 World Congress on Medical Physics and Biomedical Engineering: Medical Physics*, 27 (6): 1412, July 23-28, 2000.
4. Souza A.D.A., Ruiz E.E.S., Cruz A.A.V., Digital image analysis of extraocular muscles using the mathematical morphology, *Invest Ophthalmol Vis Sci*, 40 (4): 26, 1999.
5. Souza A.D.A., Ruiz E.E.S., Cruz A.A.V., Segmentação dos músculos extraoculares usando a morfologia matemática associado ao operador LoG, *Anais do IV FNCTS - Fórum Nacional de Ciência e Tecnologia em Saúde*, p. 465-466, 1998.

Resumo

Os *músculos extraoculares* (EOM), responsáveis pelas rotações oculares, apresentam-se aumentados em suas dimensões na orbitopatia de Graves, o que pode levar o paciente à cegueira (neuropatia óptica). Na prática clínica normalmente mede-se manualmente, em cada imagem coronal de *tomografia computadorizada por raios-X* (CT), o diâmetro desses músculos para avaliar se estes estão aumentados. A subjetividade e o tempo consumido na aquisição destas medidas são as principais deficiências desses métodos manuais. Dessa forma, apresentamos um *método de segmentação dos EOM* (MSEG) que supera as falhas, acima citadas. O MSEG proposto é baseado no detector de bordas *Laplaciano da Gaussiana* (LoG) associado à morfologia matemática. Para determinação do tamanho da máscara LoG levou-se em consideração os efeitos devido ao truncamento e a amostragem. A acurácia das medidas em modelos tridimensionais (3D) é afetada pelo *efeito de volume parcial* (PVE). Em CT, por exemplo, falsas estruturas de tecidos moles aparecem nas interfaces do osso-para-gordura e do osso-para-ar. Além disso, a pele, que tem *número CT* (ou escala de *Hounsfield*) idêntico ao tecido mole, obscurece a renderização deste. A fim de produzir imagens 3D do osso e dos tecidos moles, mais confiáveis para medidas e com melhora de qualidade, foram desenvolvidos dois *métodos de classificação dos voxels com PVE* (MCLA) baseados num novo *modelo de mistura*. A remoção da pele é realizada por meio da morfologia matemática. Renderizações volumétricas foram criadas, antes e depois de aplicar os MCLA. Experimentos qualitativo e quantitativo foram conduzidos utilizando fantoms matemáticos que simularam diferentes níveis de PVE por adição de ruído e borramento e em dados clínicos de CT. O resultado em 218 pares de medidas de áreas dos EOM realizadas em imagens coronais de CT (3 normais e 2 Graves) revelou uma boa correlação ($R=0,92$) entre o MSEG e o traçado manual. A medida de *taxa de ocupação dos EOM na órbita* (TO) feita em 33 pacientes (5 normais e 28 Graves) apresentou o maior valor no grupo Graves com neuropatia óptica, $TO=34,3\%$. Este valor é quase cinco vezes maior que o grupo normal, $TO=7,3\%$. Todos os resultados demonstraram uma melhora de

qualidade das imagens 3D depois da aplicação dos MCLA. A análise quantitativa indica que mais de 98% dos voxels com PVE foram removidos por ambos MCLA, e o segundo MCLA têm um desempenho um pouco melhor que o primeiro. Além disso, a remoção da pele torna vívidos os finos detalhes nas estruturas musculares. Medidas em modelos 3D devem ser tomadas com cuidado na radiologia em vista dos artefatos demonstrados neste trabalho, artefatos vindos, principalmente, do PVE. Em nossos experimentos, os erros nas medidas de volume dos EOM foram acima de 25% do valor estimado como “verdadeiro”. Imagens volumétricas com PVE resolvidos são apresentadas, e assim medidas mais acuradas são asseguradas.

Capítulo 1

Introdução

A presente tese desenvolve métodos e algoritmos para a segmentação, visualização e quantificação dos *músculos extraoculares* (EOM) em imagens tridimensionais (3D), principalmente no intuito de suprir a atual necessidade dos médicos em realizar medidas mais acuradas do grau de deformação dos EOM na orbitopatia de Graves. Dessa forma, o trabalho contribui com soluções efetivas para localizar e suprimir voxels com *efeito de volume parcial* (PVE) em imagens de *tomografia computadorizada por raios-X* (CT). Um método é descrito para remover a pele de forma que as renderizações com PVE resolvido do osso e do tecido mole revelem consideravelmente mais detalhes.

1.1 Motivação e objetivos

Nossa experiência em processamento de imagens aplicada à oftalmologia iniciou em 1996 com um estudo da morfologia da fenda palpebral [1], [2], [3], [4], e foi diretamente motivada por nossa colaboração com o Laboratório de Oculoplástica do Departamento de Oftalmologia da FMRP-HC, Universidade de São Paulo, Ribeirão Preto. Naturalmente, essa interação nos levou ao trabalho aqui apresentado. Neste trabalho os avanços nos estudos de visualização tridimensional, especialmente em *rendering** volumétrico direto (VR), foram frutos do apoio do *Medical Image Processing Group (MIPG)*, *Dept of Radiology, University of Pennsylvania, Philadelphia, EUA*. Tal apoio se deu por meio de um estágio entre os anos de 2000-2001 que resultou no estudo da renderização volumétrica na presença do PVE em imagens de CT [5] apresentado nesta tese.

---

* O processo de pintura, iluminação e sombreamento do modelo tridimensional gerado para apresentação na tela bidimensional do computador.

Vale ressaltar aqui que diante da pesquisa bibliográfica realizada, notamos que existem poucos trabalhos voltados para o assunto da quantificação dos EOM por imagem digital [6], alguns publicamos recentemente [7], [8], [9], [10]. Abordagens mais simples como, por exemplo, a quantificação do diâmetro dos EOM diretamente de filmes radiográficos usando pequenas réguas milimetradas são relatados [11], [12]. Além de subjetivas, tais abordagens manuais consomem muito tempo na aquisição das medidas. A questão da quantificação da musculatura extraocular adquire importância fundamental na identificação dos pacientes com orbitopatia de Graves com risco de desenvolvimento de neuropatia óptica – lesão do nervo óptico podendo levar o paciente à cegueira [13], [14], [15]. Dessa forma, uma análise tridimensional é necessária para informar sobre o volume, a forma das deformações e localização dos EOM. Nesse aspecto, a presente tese faz uma contribuição original e inédita apresentando uma metodologia para segmentação, visualização e quantificação dessas estruturas.

Em visualização 3D, o nosso trabalho contribui com novos métodos que efetivamente localizam e suprimem os voxels com PVE, e também removem a pele que causa obscurecimento das renderizações do tecidos mole (músculo) e ósseo. Na última década, muitos trabalhos sobre segmentação e visualização 3D relatam sobre a importância da redução do PVE para produção de imagens volumétricas com qualidade de detalhes e confiáveis para medidas [16], [17], [18], [19], [20], [21], [22]. Os métodos propostos para classificar os voxels com PVE adotam um novo *modelo de mistura* [5], que são baseados no seguinte postulado: “*Em qualquer imagem adquirida, voxels com incerteza mais alta ocorrem próximos à borda do objeto.*” [23]. O método aqui descrito para remover a pele baseando-se em morfologia matemática é também original e inédito.

1.2 Materiais

O primeiro conjunto de imagens de CT (TOMOSCAN SR 4000 da Philips Medical Systems) foi obtido junto ao Laboratório de Oculoplástica do Departamento de Oftalmologia da FMRP-HC, Universidade de São Paulo, Ribeirão Preto. Essas imagens foram utilizadas para implementação e validação dos métodos de segmentação dos EOM. Imagens coronais de CT da órbita de diferentes grupos de pacientes foram utilizadas na quantificação da musculatura extraocular (Capítulo 3, seção 3.5). Os dados utilizados para o desenvolvimento e validação dos métodos de classificação de voxels com PVE foram obtidos junto ao MIPG do Departamento de Radiologia da

Universidade da Pensilvânia, Filadélfia. Os programas foram implementados e testados em computadores PC. As ferramentas utilizadas no trabalho basearam-se no ambiente de processamento de imagem do MATLAB [24] associado ao *SDC Morphology Toolbox* [25], nos sistemas de visualização volumétrica do VTK [26] e do 3DVIEWNIX [27] e na linguagem C.

1.3 Estrutura da tese

A tese está dividida em cinco capítulos, descritos como se segue abaixo.

O Capítulo 1 corresponde à introdução da presente tese. A motivação, os objetivos e os materiais utilizados no trabalho são apresentados.

O Capítulo 2 apresenta os conceitos básicos sobre segmentação em imagens digitais, com ênfase na descrição do detector de bordas, o operador Laplaciano da Gaussiana, e na morfologia matemática. Uma breve revisão sobre visualização volumétrica é feita abordando alguns algoritmos de reconstrução 3D. Na seção 2.3, o fenômeno do efeito de volume parcial é discutido e na seção 2.4, aborda-se o problema da deformação dos EOM em pacientes com orbitopatia de Graves.

O Capítulo 3 apresenta uma solução de segmentação, visualização e quantificação dos EOM. O método de segmentação dos EOM é descrito, os resultados de desempenho da segmentação semi-automática e um estudo quantitativo dos EOM são também apresentados neste capítulo.

O Capítulo 4 aborda sobre a renderização volumétrica na presença de PVE. Os métodos de identificação e supressão dos voxels afetados pelo PVE são apresentados. Em seguida, o método para a remoção da pele é descrito. Os resultados do desempenho destes métodos são apresentados em imagens de CT de pacientes e num fantom matemático.

O Capítulo 5 revisa os objetivos da tese e apresenta as conclusões obtidas com o trabalho.

O *Anexo Colorido* disponibiliza em cores as figuras marcadas com a palavra sobrescrita *cor* (e.g. Fig. 3.22^{cor}) que aparecem ao longo do texto da tese em preto-e-branco.

Capítulo 2

Conceitos Básicos

2.1 Segmentação em imagem digital

A segmentação é o processo que divide uma imagem nos seus elementos constituintes ou objetos. Ela representa uma das mais importantes tarefas na análise de imagens digitais bidimensionais e tridimensionais porque é nesta etapa que objetos de interesse são extraídos da imagem para subsequente processamento, visualização e análise. Dessa forma, a definição de objetos parece ser vital em qualquer aplicação com imagens, como por exemplo, em imagens médicas. Nesta tese a segmentação de imagem é realizada quando extraímos os EOM de uma imagem tomográfica da região anterior do globo ocular. Uma extensa revisão sobre o assunto é dada em Pal & Pal [28].

Um breve comentário sobre o conceito de imagem digital é dado a seguir. O leitor pode buscar mais informações sobre o assunto em diversos livros e artigos de processamento de imagem, dentre eles citamos [29], [30], [31], [32] e [33]. Uma imagem digital monocromática pode ser representada como um conjunto de pontos discretos em tons de cinza. Uma imagem digital é uma função de intensidade de luz $f(x,y)$ discretizada em ambas coordenadas espaciais (x,y) e no valor digital do ponto. Considera-se uma imagem digital monocromática, uma matriz em que os índices das linhas e colunas identificam o ponto na imagem e o correspondente valor do elemento da matriz identifica o tom de cinza no ponto (Fig. 2.1). Os elementos de tais arranjos são chamados de elementos de imagem ou, mais comumente, *pixels*. O pixel é representado por um quadrado com dimensões $\Delta x = \Delta y = p$. Quando a imagem possui apenas dois valores distintos, geralmente $f(x,y)$ igual a zero ou um, ela é dita ser uma imagem binária. Por sua vez, uma imagem $f(x,y)$ com 8 bits de tons de cinza pode

assumir até 2^8 ou 256 valores diferentes. Estes valores de tons de cinza são representados por um conjunto de inteiros, na maioria dos casos valores inteiros entre 0 e 255. Analogamente, uma imagem monocromática de 12 bits possui 2^{12} ou 4096 valores distintos. As imagens tridimensionais são discutidas na seção 2.2, p. 10.

Fig. 2.1. Processo de representação digital de uma imagem.

Limiarização

A técnica mais popular de segmentação de imagem é a limiarização, ou binarização, por causa de sua simplicidade. Esta operação está, quase sempre, embutida em soluções avançadas de segmentação [28]. A limiarização consiste basicamente em determinar *objetos de interesse* numa imagem (e.g. EOM) indicando um intervalo de tons de cinza $[l_{\min}; l_{\max}]$ que estes objetos pertencem. Neste caso o histograma da imagem original auxilia na escolha deste intervalo e os objetos segmentados são mostrados na imagem binária resultante (Fig. 2.2).

Fig. 2.2. Limiarização.

Laplaciano da Gaussiana

O Laplaciano da Gaussiana (LoG) é comumente empregado como um detector de bordas, de segunda-ordem, em processamento de imagem. A sua popularidade é devida às suas propriedades escalares, desde quando foi apresentado por Marr e Hildreth [34], como um modelo fisiológico do sistema primário de visão humana.

O LoG é um operador multi-resolução que pode ser aplicado em várias escalas. Este operador é empregado em vários detectores [35], [36], onde a escala da característica de interesse é geralmente desconhecida. A implementação do LoG num ambiente de processamento de imagem requer uma amostragem finita aproximada pois o LoG estende-se ao infinito em ambos domínios: espacial e da frequência. Conseqüentemente, cuidados devem ser tomados na sua aplicação como um detector de bordas num domínio finito. O uso de versões aproximadas da função LoG truncada em seus extremos é normalmente empregado. Entretanto, os pontos de truncamento são geralmente obtidos por heurística, tal como uma constante que multiplica a distância d_{zc} entre os pontos de passagem pelo zero ou *zero-crossing* da função LoG (p. 27 , Fig. 3.1). A escolha mal feita desta constante leva, quase sempre, a pobres detectores de bordas [35]. Assim, para gerar uma rigorosa determinação da máscara LoG (Capítulo 3, seção 3.2.1) adaptada ao problema de segmentação dos EOM [10], uma teoria baseada na fração de energia ignorada devido ao truncamento do LoG é utilizada [35].

Uma função Gaussiana bidimensional (2D) de escala σ é dada por:

$$G_{\sigma}(x,y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right). \quad (2.1)$$

O Laplaciano da Gaussiana é dado por:

$$\nabla^2 G_{\sigma}(x,y) = \frac{-1}{2\pi\sigma^4} \left(2 - \frac{x^2 + y^2}{\sigma^2}\right) \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right). \quad (2.2)$$

A função LoG é isotrópica (ou seja, simétrica em todas as direções) no domínio espacial, tal isotropia é evidenciada na equação (2.2). A Fig. 2.3 mostra a função Gaussiana 2D e o correspondente Laplaciano da Gaussiana. Vale lembrar que as bordas, na teoria de Marr-Hildreth, são determinadas pelo *zero-crossing* de uma imagem convolvida com a máscara LoG.

Fig. 2.3. A Função Gaussiana 2D e o respectivo Laplaciano da Gaussiana.

Morfologia matemática

A morfologia matemática, criada por Georges Matheron e Jean Serra, permite o processamento de uma imagem baseando-se na sua forma geométrica [37], [38]. Serra comentou, em referência ao processamento de imagem por morfologia matemática, que a imagem contém *informação* demais, e o objetivo de qualquer tratamento morfológico é “administrar a perda desta *informação*” por meio de sucessivas transformações. Ou seja, o princípio básico da morfologia matemática é a extração de *informações* de uma imagem baseada na forma (geometria e topologia) dos objetos na imagem. A grande potencialidade da morfologia matemática reside no elemento estruturante, um conjunto completamente definido em forma e tamanho, que é comparado ao conjunto desconhecido da imagem por uma transformação. A forma do elemento estruturante define o resultado produzido pelo filtro morfológico. Na seção 3.2.2, p. 32, utilizaremos dois tipos de elementos estruturantes: cruz e disco. Estes elementos estruturante são representados como um arranjo de pixels “•” (ativos com valores iguais a um) ou “.” (inativos com valores iguais a zero), ver Fig. 3.9, p. 34 e Fig. 3.11, p. 36. Uma breve introdução aos filtros morfológicos segue abaixo. Para uma discussão completa e formal veja [37], [38], [39], [40], [41] e [42].

Existem dois tipos de processamento morfológicos: a morfologia binária aplicada nas imagens binárias e a morfologia cinzenta aplicada nas imagens com tons de cinza. Na morfologia binária é procurada uma configuração, o *elemento estruturante*, na vizinhança de cada pixel da imagem original. Se encontrada, o pixel correspondente da imagem resultante é rotulado como “verdadeiro” (valor do pixel igual a um), senão o pixel resultante é dado como “falso” (valor do pixel igual a zero).

Na morfologia cinzenta é preciso conhecer o valor máximo do pixel (mais claro) e mínimo (mais escuro) na vizinhança de cada pixel da imagem original ou numa parte dela. O resultado da aplicação morfológica dependerá de uma combinação destes valores.

Para evitar confusão entre as notações adotadas pelos diferentes autores, as principais operações morfológicas, seguindo as notações de Facon [42], são apresentadas abaixo:

1) *Erosão*: esta operação reduz a área do objeto. Numa imagem binária, a erosão da imagem X pelo elemento estruturante B pode ser expressa pela equação (2.3), como um conjunto de pontos x onde B_x (elemento estruturante centrado em x) está posicionado de tal forma que B fica completamente contido em X :

$$X_{\text{ero}}B = \{x \in X \mid B_x \subset X\}. \quad (2.3)$$

Nas imagem com tons de cinza, a erosão verifica se B_x está abaixo dos valores dos pixels da imagem f , equação (2.4) abaixo:

$$X_{\text{ero}}B = \text{MIN} \{f(y) - B(x - y) : y \in C\}, \quad (2.4)$$

onde C é o domínio da imagem f .

Note que a erosão não é definida num ponto onde o elemento estruturante não está abaixo dos valores dos pixels da imagem f .

2) *Dilatação*: esta é a operação dual da erosão, e o seu efeito é aumentar a área do objeto. No caso da morfologia binária, o complemento da proposição “ B_x está incluído em X ” é a proposta “a interseção de B_x e X não é vazia”, definida como:

$$X_{\text{dil}}B = \{x \in X \mid B_x \cap X \neq \emptyset\}. \quad (2.5)$$

Pela equação (2.5), uma possível interseção B_x com X é verificada, posicionando e centrando o elemento estruturante B_x em cada pixel x de X . Caso aconteça interseção, o pixel x (ponto central de B_x) na imagem resultante será marcado como “verdadeiro”. Caso contrário, ele será marcado como “falso”. Em analogia com a erosão, a dilatação nas imagens em tons de cinza verifica se B_x está acima dos valores dos pixels da imagem f , equação (2.6) abaixo:

$$X_{\text{dil}}B = \text{MAX} \{f(y) + B(x - y) : y \in C\}. \quad (2.6)$$

3) *Abertura e Fechamento*: as operações primitivas de dilatação e erosão são geralmente aplicadas sequencialmente usando o mesmo elemento estruturante. Estas combinações são as operações de abertura e fechamento. A abertura elimina partículas indesejáveis sem modificar o tamanho das outras entidades. Isto é, aplica-se uma operação de erosão seguida por uma dilatação. Esta operação pode ser expressa pela equação (2.7) como:

$$X \text{ *abe* } B = (X \text{ *ero* } B) \text{ *dil* } \tilde{B}. \quad (2.7)$$

Onde $\tilde{B}$ é chamado de B transposto. A abertura suaviza os contornos pelo interior, separa as partículas e elimina as pequenas partículas inferiores em tamanho ao elemento estruturante B .

O fechamento é uma operação dual da abertura. O fechamento troca simplesmente a ordem das operações, tal que X é primeiro dilatado e então erodido:

$$X \text{ *fec* } B = (X \text{ *dil* } B) \text{ *ero* } \tilde{B}. \quad (2.8)$$

O fechamento suaviza as fronteiras pelo exterior, conecta as partículas próximas e preenche os buracos no interior das partículas.

2.2 Visualização volumétrica

O estudo dos métodos e algoritmos de reconstrução 3D é parte integrante do processo conhecido como *Visualização Volumétrica*, ver Fig. 2.4. O termo visualização pode ser entendido como a transformação de dados ou *informações* numa imagem. A visualização utiliza-se do sentido primário humano, a visão, bem como o poder de abstração (processamento) da mente. O resultado é um meio simples e efetivo para comunicar *informações* complexas e/ou volumosas [26], [43].

A visualização científica (ViSC) é o nome formal dado ao campo da Ciência da Computação que engloba linhas de pesquisas tais como: interface do usuário, representação dos dados, algoritmos de processamento, representações visuais, e outras apresentações sensoriais, como o som e o tato [44], [45], [46], [47], [48].

Fig. 2.4. Processo de visualização volumétrica para imagens médicas.

Uma das mais interessantes áreas da ViSC, e também a que mais cresce hoje, é a visualização volumétrica [49]. Na medicina, a visualização volumétrica tem avançado para um estágio não imaginado 100 anos atrás quando Wilhelm Roentgen recebeu o prêmio Nobel de Física pela descoberta dos raios-X. Esse desenvolvimento está relacionado ao surgimento de equipamentos de aquisição de dados 3D, tais como: tomografia computadorizada por raios-X (CT), tomografia por emissão de pósitron (PET), tomografia por emissão de fóton (SPECT), ultra-sonografia (US), a imagem por ressonância magnética (MRI), e ao rápido avanço da tecnologia de computadores que hoje acelera ainda mais as pesquisas em visualização volumétrica aplicada à medicina [50], [51], [52].

Novos procedimentos e algoritmos têm surgido freqüentemente com o propósito de reduzir o alto *custo** computacional na visualização volumétrica e a grande quantidade de memória requerida [53], [54], [55], [56], [57].

Esses procedimentos e algoritmos podem também ser úteis na heurística do desenvolvimento do processo de visualização da musculatura extraocular. Os dados volumétricos na área médica são adquiridos em forma de imagens 2D (fatias) paralelas e espaçadas uniformemente ao longo do volume de interesse (Fig. 2.4). O empilhamento dessas fatias produz uma malha cartesiana com atributos escalares, como veremos abaixo em *Descrição do volume*.

É bom lembrar que operações de processamento de imagem podem ser incluídas no processo de visualização volumétrica. A escolha das operações e a sua ordem de aplicação dependem fortemente da natureza dos dados, dos objetivos do estudo e da técnica de visualização adotada. Vários passos do processo de visualização volumétrica (Fig. 2.4) são comuns nos diferentes tipos de algoritmos usados para alcançar a visualização [58]. Neste trabalho, o processamento de imagem é realizado quando extraímos e quantificamos os EOM (Capítulo 3). As renderizações volumétricas (SR e VR, ver definições na p. 14) são produzidas a partir de dados CT volumétricos com PVE resolvido (Capítulo 4).

Os algoritmos descritos aqui foram *a priori* idealizados para visualizar dados volumétricos escalares. Porém, algumas técnicas podem ser utilizadas para visualização de dados vetoriais, tensoriais, bi-modais, e de dimensões maiores. Antes da descrição dos algoritmos é necessário definir alguns termos para evitar confusão, e assim proporcionar um melhor entendimento das técnicas.

Descrição do volume

O *voxel* (elemento de volume) em imagens médicas é a forma representativa do dado de volume adquirido sob forma de uma imagem bidimensional de um corte transversal ao eixo longitudinal do paciente. O valor numérico (tom de cinza) associado ao voxel é chamado densidade do voxel. Por exemplo, cada voxel em uma imagem de CT tem um tom de cinza que é proporcional à densidade do tecido. Quanto maior a densidade do tecido maior será a atenuação de raios-X e, portanto, maior será o tom de cinza dos voxels deste tecido. A atenuação é expressa na escala de *Hounsfield*†, também conhecida

---

* Tempo de processamento de uma aplicação.

† G. Hounsfield ganhou o prêmio Nobel em 1979 por inventar o tomógrafo de raios-X.

como *número CT*. Dessa forma, nas imagens por CT (Fig. 2.4) o osso aparece em tons de cinza mais claro (alta densidade) e o ar aparece em tons de cinza mais escuro (baixa densidade).

Por definição, o voxel tem o mesmo valor do dado volumétrico contido no seu interior, como visto na Fig. 2.5.

Fig. 2.5. Os cubóides representam os voxels em imagens médicas. Os pontos pretos no interior de cada voxel representam os dados volumétricos.

É importante ressaltar que um conjunto de dados volumétricos possui uma organização estrutural (*malha*) inerente aos seus atributos (escalar, vetor, tensor, etc.). A estrutura, por sua vez, tem propriedades geométricas e topológicas dependentes da natureza dos dados volumétricos. A geometria está associada à posição no espaço (x, y, z) . A topologia pode ser associada aos voxels da estrutura volumétrica (e.g. cubos, hexaedros, tetraedros, etc.), além de indicar um conjunto de propriedades invariantes sob certas transformações geométricas.

A Fig. 2.6 exemplifica os tipos de estruturas. As imagens médicas se enquadram no tipo de conjunto de dados volumétricos classificados como malha cartesiana com atributos escalares, isto é, todos os voxels são cubóides idênticos e justapostos formando um bloco volumétrico.

Fig. 2.6. Tipos de malhas.

Algoritmos de visualização volumétrica

Os algoritmos fundamentais de visualização volumétrica pertencem a uma das duas categorias, e são elas:

1. *Surface rendering* (SR) – *rendering* superficial.
2. *Volume rendering* (VR) – *rendering* volumétrico.

Ambos algoritmos tem vantagens e desvantagens que devem ser consideradas para um resultado efetivo em problemas clínicos.

Nos algoritmos de SR, uma reconstrução 3D do volume pode ser realizada em computadores modestos porque o algoritmo modela o volume como uma coleção de primitivas geométricas (normalmente triângulos) mostrada na tela do computador como superfícies ocas. Os algoritmos de SR percorrem a estrutura de dados volumétrica uma única vez para extrair as superfícies, por isso são geralmente mais rápidos que os algoritmos de VR. Entretanto, sobreposições de estruturas não podem ser visualizadas e artefatos são um problema. Além disso, menos de 10% dos dados do volume são usados [50], [59].

Já os algoritmos de VR usam quase 100% dos dados do volume e, portanto, requerem mais poder computacional tornando o processo de renderização lento e o

consumo de memória elevado. Embora os algoritmos de VR possibilitem a visualização de sobreposições de estruturas e produzam renderizações de melhor qualidade que aquelas baseadas em SR, o seu uso é limitado pelas deficiências apontadas acima. Nos últimos anos, vários algoritmos têm sido propostos no sentido de suprir as falhas acima citadas [53], [54], [55], [56], [57]. Dentre estes, o algoritmo *shell-rendering* desenvolvido por Udupa e Odhner [53] é utilizado neste trabalho (Capítulo 4). Os algoritmos de VR utilizam duas tabelas de valores: cor e opacidade (atenuação da luz) para mapear os valores de tons de cinza dos voxels do volume real.

A Tabela 2.1 mostra uma taxonomia dos algoritmos descritos aqui.

Tabela 2.1. Algoritmos de visualização volumétrica.

ALGORITMOS DE VISUALIZAÇÃO VOLUMÉTRICA	
<i>Rendering</i> superficial (SR)	<i>Rendering</i> volumétrico (VR)
1. <i>Contour-connecting</i> .	1. <i>Ray-casting</i> .
2. <i>Opaque cubes (cuberille)</i> .	2. <i>Shell-rendering</i> .
3. <i>Marching cubes</i> . <i>Dividing cubes</i> . <i>Marching tetrahedral</i> .	

2.2.1 *Rendering* superficial

Contour-connecting

Um dos primeiros métodos para produzir imagens 3D foi a partir de contornos planares, conhecidos como algoritmos de *contour-connecting* [60], [61]. A idéia básica destes algoritmos é traçar contornos fechados em cada fatia e, então, conectar os contornos adjacentes. Ainda existem vários problemas a serem resolvidos nestas técnicas, desde a extração dos contornos (segmentação) por meio de técnicas de processamento de imagem até os problemas de tecelagem (triangulação de contornos), ver Fig. 2.7a.

Fig. 2.7. *Rendering* superficial por triangulação de contornos (a), e faces de voxels (b).

Opaque cubes (cuberille)

A dificuldade das técnicas baseadas em *contour-connecting*, devido a suas ambigüidades topológicas e a necessidade da intervenção manual, foi completamente superada pelo novo método de SR baseado em uma interpretação por cubos da cena [62] (Fig. 2.7b). Esse algoritmo consiste de dois estágios: no primeiro, uma operação de limiarização é realizada (p.6, limiarização) e os voxels classificados são conectados. O segundo passo é o *rendering* do modelo 3D. O algoritmo tem duas vantagens:

- a. isola o objeto de interesse das estruturas vizinhas; e
- b. calcula o volume do objeto.

Marching cubes

O algoritmo de SR mais popular é o *marching cubes*, proposto por Lorensen e Cline [63], este algoritmo é muito empregado, ainda hoje, em diversas aplicações médicas. Lorensen é também um dos autores do sistema de visualização VTK empregado nesta tese (Capítulo 3). Dado um valor de limiar, as *células* (um cubo formado por oito voxels vizinhos como vértices; quatro de uma dada fatia k e quatro da fatia $k+1$) que contribuem para formação da superfície são pesquisadas. Os autores analisaram 256 possíveis configurações das intercessões dos triângulos (no máximo quatro triângulos por *célula*) com uma *célula* cúbica a partir dos valores dos seus vértices e por argumentos de simetria (reflexão, rotação). Estes casos foram reduzidos para 15, como mostra a Fig. 2.8. Os pontos pretos (visíveis) e brancos (invisíveis) representam os vértices com valores acima do limiar.

Fig. 2.8. *Marching cubes*: as configurações básicas para triangulação de uma única *célula*.

As operações desses algoritmos são sumarizadas a seguir:

- a. detecção dos vértices cujos valores estão acima do limiar e cálculo de um índice para uma tabela de intercessão de bordas definindo a configuração dos triângulos dentro da *célula*;
- b. definição dos vértices dos triângulos por interpolação linear entre os valores dos vértices das *células*;
- c. cálculos dos gradientes em cada vértices das *células* para utilização no processo de sombreamento; e
- d. *rendering* do modelo 3D.

Marching tetrahedra

Alguns autores têm apontado possíveis ocorrências de ambigüidades e falsos buracos nas superfícies. E para remover essas ambigüidades critérios adicionais devem ser aplicados, são entre eles destacados:

1. Escolha de uma configuração preferencial nos casos de todas as faces serem ambíguas [64].
2. Decomposição da *célula* em tetraedros, resultando num número maior de triângulos por cada *célula* [65].
3. Variação bilinear sobre as faces ambíguas [66].
4. Examinar a superfície interna por interpolação trilinear [67].

2.2.2 Rendering volumétrico

Ray-casting

Um algoritmo de VR bastante conhecido é o *ray-casting* [68], [69], [70], [71], [72]. Como a maioria dos algoritmos de VR, o *ray-casting* reconstrói todo o volume contínuo do conjunto de dados discretos por meio de alguma função de interpolação de ordem-zero ou maior. Então, essa função é reamostrada e projetada na tela 2D produzindo a imagem final. Esse algoritmo usa a técnica *image-order* [73], [74] que dispara raios partindo dos *pixels* (elementos de imagens). Estes raios atravessam todo o volume somando os valores de cor e opacidade ao longo dos raios e, assim, definindo a contribuição dos *pixels* na imagem final. Outros algoritmos podem empregar uma técnica oposta, no sentido do volume para a imagem (*object-order*) [53], [75], ou uma combinação das duas técnicas. Uma discussão sobre os vários algoritmos de VR pode ser visto em [58] e [52].

Shell-rendering

Este algoritmo de VR, proposto por Udupa e Odhner [53], representa todo o volume usando uma nova estrutura de dados, a *shell*. A *shell* reduz drasticamente a quantidade de memória e o tempo de *rendering* (p. 1, ver nota de rodapé), além de reter a nebulosidade inerente dos dados medidos ou simulados. *Shell-rendering* é um novo paradigma para visualização de volumes e, ainda, a sua representação explícita do volume permite a realização de *morfometria** de superfícies numa técnica de VR. Este algoritmo será utilizado nos experimentos de *rendering* volumétrico na presença do PVE (Capítulo 4).

Resumidamente, uma *shell* contém um conjunto de voxels próximos à borda das estruturas e associados a um número de atributos. Geralmente este conjunto de voxels é um subconjunto do volume total, mas também pode conter todo o volume. Somente os voxels da *shell*, que potencialmente contribuem para o processo de renderização, entrarão na computação principal de *rendering*. Logo, requerimentos computacionais e de armazenagem são efetivamente reduzidos, escolhendo cuidadosamente os atributos e armazenando a *shell* numa estrutura de dados especial que permita o acesso aleatório aos voxels e a seus atributos. O *shell-rendering* usa a técnica *object-order* que elimina a

---

* Embora o termo tenha aplicação ampla na ciência, o sentido em biomedicina, em última análise, seria a "atividade de medir estruturas anatômicas".

necessidade de interpolação em tempo real e, conseqüentemente, acelera ainda mais este algoritmo de VR.

2.3 O efeito de volume parcial

O *efeito de volume parcial* (PVE) é um problema freqüente quando queremos visualizar estruturas numa imagem médica. Para visualizar as estruturas de interesse, presentes nos dados volumétricos originais, os dados devem ser primeiramente classificados [70], [50], [68]. A classificação determina uma porcentagem dos diferentes tecidos dentro de cada voxel. A idéia é estabelecer uma relação nebulosa (fuzzy) entre as transições dos *diferentes tecidos* (Fig. 2.9a), como exemplificado na Fig. 2.9b. Após a classificação dos tecidos, é possível decidir quais deles serão realçados ou suprimidos na renderização volumétrica. Assim uma função de opacidade é determinada de forma que as estrutura mais visíveis terão uma opacidade alta, e as estruturas transparentes uma opacidade baixa (Fig. 2.9c).

Entretanto, o PVE geralmente ocorrido nas interfaces dos tecidos (Fig. 2.10) afeta a qualidade das renderizações introduzindo artefatos (falsos positivos). Nos últimos 10 anos, métodos específicos têm sido apresentados para superar este problema [5], [16], [17], [18], [19], [20], [21], [22]. O PVE está estritamente relacionado à resolução de aquisição do dado volumétrico (e.g. CT, MRI e outros). Em CT, pesquisas têm sido conduzidas no intuito de reduzir a espessura da fatia, e assim reduzir o PVE. Porém, a limitação no tempo de aquisição devido ao aumento da dose de radiação no paciente torna ainda mais difícil a redução da espessura das fatias em CT. Além disso, um outro fator causador do PVE é o movimento do paciente durante a aquisição da imagem. Dessa forma, *métodos de classificação dos voxels com PVE* (MCLA) são apresentados para reduzir os artefatos vindo do PVE em imagens de CT (Capítulo 4).

Fig. 2.9. (a) Distribuição em tons de cinza dos diferentes tecidos. (b) Uma relação nebulosa (fuzzy) entre as transições dos diferentes tecidos. (c) Função de opacidade.

Fig. 2.10. Ilustração do efeito de volume parcial.

2.4 Deformação dos músculos extraoculares na orbitopatia de Graves

As deformações sofridas nos músculos extraoculares (EOM) na orbitopatia de Graves, são bem conhecidas [13], [14]. Os músculos (Fig. 2.11) que compõe a EOM são: os *retos medial, lateral e inferior*; os *oblíquos inferior e superior*; e o *reto superior* que aparece geralmente junto ao elevador da pálpebra superior. Chamaremos de *complexo superior* o

conjunto formado pelo reto superior e o elevador da pálpebra superior. Com o efeito no curso dessa doença orbital, ocorre um aumento no diâmetro do músculo afetado e conseqüente desenvolvimento de *fibrose**. Além dos óbvios efeitos sobre o movimento do olho (oculomotricidade), o alargamento dos EOM é apontado como um dos fatores causais mais importantes na origem da *neuropatia óptica*. A neuropatia óptica é uma lesão compressiva no nervo óptico podendo levar o paciente à perda de visão [76].

Fig. 2.11. Musculatura extraocular (adaptada do *Atlas visual*, ed. Ática, 1996).

Uma abordagem simples para medir o alargamento dos EOM na orbitopatia de Graves é a quantificação, em milímetros, do diâmetro da musculatura no sentido horizontal e vertical da órbita. Esta é a avaliação feita, de maneira subjetiva e manual, pelos radiologistas, quando investigam laudos afirmando que um determinado músculo está com suas dimensões aumentadas [12]. Curiosamente não há dados tomográficos disponíveis na literatura sobre as dimensões normais dos músculos extraoculares. O problema é de certo modo complexo porque qualquer medida de diâmetro muscular deve estar, para efeito comparativo, relacionada a uma mesma posição dentro da órbita. Isto é, se a medida for perto do tendão ela não pode ser comparada com outra realizada na metade da órbita, pois as dimensões musculares podem não ser as mesmas [11], [12], [15]. Uma metodologia para quantificação do EOM (p. 39, seção 3.3) é apresentada no

* A formação de tecido fibroso resultante do processo de cicatrização do tecido irritado.

sentido de estabelecer uma normalização destas medidas de modo que as dificuldades apontadas acima sejam superadas. As imagens de CT (Fig. 2.12) e a MRI auxiliam os principais métodos de estudo da deformação da musculatura extraocular nesse tipo de orbitopatia (a doença de Grave). Os exames de imagem revelam frequentemente um alargamento dos EOM nos pacientes com orbitopatia de Graves (Fig. 2.13).

Fig. 2.12. Imagem CT coronal da órbita de um paciente normal.

Fig. 2.13. Imagem CT coronal da órbita de um paciente com orbitopatia de Graves. As setas brancas indicam os músculos alargados.

A *taxa de ocupação muscular na órbita* TO é invariavelmente abordada nesses estudos das deformações dos EOM [77], [78]. Embora, teoricamente, esta abordagem seja correta, a mera quantificação do volume nada instrui sobre a forma da estrutura muscular comprometida pela doença. Desse modo, a visualização 3D dos EOM [2], [5] que oferece um meio mais simples para o entendimento de complexas relações anatômicas, pode ser a base de um estudo quantitativo mais acurado do grau de deformação destes músculos. A questão da quantificação da musculatura extraocular adquire importância fundamental na identificação dos pacientes com orbitopatia de Graves com risco de

desenvolvimento de neuropatia óptica. Embora a prevalência do envolvimento do nervo óptico na orbitopatia de Graves não seja bem estimada, a detecção da neuropatia óptica é importante, pois uma vez presente, o tratamento da orbitopatia de Graves muda radicalmente e terapias mais agressivas, como a descompressão óptica, podem ser indicadas [14].

Capítulo 3

Quantificação da Musculatura Extraocular por Imagem Digital

3.1 Introdução

Numa análise de imagens médicas (e.g. CT, MRI e outras), os métodos automáticos de segmentação podem realizar um estudo exaustivo de investigação em numerosas estruturas em poucos minutos. Por exemplo, numa imagem CT coronal de órbita (p. 22, Fig. 2.12) são tipicamente apresentados oito objetos (secção transversal dos EOM) de interesse. Num estudo quantitativo da deformação dos EOM na orbitopatia de Graves, os oftalmologistas medem usualmente os diâmetros (comprimento do eixo vertical e horizontal) destes oito objetos, em sete imagens CT coronal espaçadas uniformemente ao longo da região orbital de cada paciente, no intuito de identificar e classificar pacientes com orbitopatia de Graves com o risco de desenvolver neuropatia óptica [11], [12], [15]. Caso este estudo envolva medidas em 30 pacientes, o médico efetuará aproximadamente 1400 medidas de diâmetro, o que poderá levar dias ou meses.

É inquestionável o benefício dos métodos de segmentação automática, dado o exposto acima. Entretanto, existem e sempre existirão situações em que os métodos automáticos falharão, dependendo de considerável assistência do médico especialista (o usuário) [79], [80]. Desta forma métodos semi-automáticos, ou interativos, oferecem um balanço entre a automatização da segmentação e o processo cognitivo humano de reconhecimento de objetos e bordas produzindo técnicas mais robustas de segmentação [81]. Atualmente métodos semi-automáticos específicos têm provado ser a base para soluções efetivas, principalmente, em imagens médicas [82],[83] [3], [4], [7], [8], [9], [10].

Um *método semi-automático de segmentação dos EOM* (MSEG) [9], [10] será descrito ao longo deste capítulo e utilizado num estudo quantitativo envolvendo 33 pacientes (5 normais e 28 pacientes com orbitopatia de Graves), ver seção 3.4, p. 45. Um modelo 3D superficial dos EOM é proposto baseando-se no algoritmo de SR, *marching cubes*. Este modelo foi avaliado quantitativamente medindo-se o volume e área superficial dos EOM e de fantoms matemáticos (seção 3.3).

3.2 Segmentando os músculos extraoculares

Os EOM podem ser identificados por algumas de suas características (p. 22, Fig. 2.12):

- a. padrão elíptico ou circular;
- b. área que mede entre $3,0 \text{ mm}^2$ a aproximadamente 18 mm^2 ;
- c. tons de cinza mais alto que as estruturas vizinhas; e
- d. o comprimento do menor eixo dos EOM nas imagens CT coronais estudadas foi aproximadamente $3,0 \text{ mm}$.

Tais imagens CT coronal da órbita foram disponibilizadas pelo Laboratório de Oculoplástica da FMRP-HC, que conduz atualmente pesquisas médicas investigativas sobre a causa e o efeito da deformação dos EOM na orbitopatia de Graves utilizando imagens de CT [11], [12]. Estas imagens de CT são tipicamente digitalizadas num scanner específico para filme radiológico em 8 bits de tons de cinza com o tamanho do pixel igual a $0,40 \text{ mm}$.

Vale ressaltar nesse ponto que o intuito do trabalho é primeiramente suprir a necessidade atual dos oftalmologistas do FMRP-HC que realizam estudos quantitativos nos EOM, por meio de traçado manual, nas imagens acima descritas. Entretanto os métodos propostos podem ser facilmente aplicados em imagens usuais de CT com 12 bits de tons de cinza.

3.2.1 Produzindo uma máscara LoG ótima

Neste trabalho os efeitos devidos ao truncamento e a amostragem serão levados em conta para a implementação da *máscara* (matriz pequena) LoG no domínio finito da imagem. Logo, para gerar um detector de bordas acurado baseado no LoG adotamos uma base matemática relatada em [35], e a aplicamos no problema de segmentação dos

EOM. Esta implementação proposta aqui produz um operador LoG isotrópico* com tamanho adequado à segmentação dos EOM [10].

A Fig. 3.1 ilustra o erro devido ao truncamento da função contínua LoG. Este erro pode ser quantificado pela grandeza ε_s , a fração de energia ignorada devido ao truncamento da função LoG no domínio espacial, abaixo:

$$\varepsilon_s = 1 - \frac{\int_{-l}^l \int_{-l}^l (\nabla^2 G_\sigma(x,y))^2 dx dy}{\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (\nabla^2 G_\sigma(x,y))^2 dx dy}, \quad (3.1)$$

onde $\nabla^2 G_\sigma(x,y)$ é a função LoG.

Fig. 3.1. Truncamento da função contínua LoG (secção transversal).

Conseqüentemente, ε_s é obtido quando limitamos a função LoG a um dado intervalo fixo $(-l, l)$, o que denota uma região quadrada $2l \times 2l$. Para um experimento em que mantemos l fixo e variamos a escala σ , nota-se que o erro da energia ε_s decresce quando o σ decresce. Esse comportamento pode ser facilmente entendido pois quando a escala σ decresce, a representação da função LoG torna-se mais compacta no domínio espacial. Logo para uma região fixa qualquer tomada, o truncamento da função LoG também será menor.

Além do erro da energia ε_s , o truncamento introduz adicionalmente uma assimetria (ou anisotropia) na função LoG. Tal assimetria quebra a fundamental propriedade de

---

* Esta propriedade garante que o resultado da soma de todos elementos (valores) da máscara LoG seja zero.

isotropia da função LoG, levando à um detector de bordas pobre que responderá preferencialmente às bordas côncavas ou convexas, desde que a resposta para as partes planas da imagem não será mais igual a zero. De modo a evitar este problema, um fator de correção κ é adicionado ao operador truncado, logo temos:

$$\kappa = -\frac{1}{4l^2} \int_{-l}^l \int_{-l}^l \nabla^2 G_{\sigma}(x,y) dx dy. \quad (3.2)$$

Tal efeito tem sido comumente negligenciado devido a incorreta implementação do operador LoG [35].

A classificação das bordas após a convolução do LoG na imagem é normalmente feita pela passagem pelo zero ou *zero-crossing*. Logo, um erro na detecção dos *zero-crossing* é também introduzido quando a máscara LoG truncada é convolvida com a imagem. É possível provar matematicamente que a probabilidade do erro na detecção dos *zero-crossing* (P_{erro}) de uma dada imagem pode ser expressa como função do erro da energia $\mathcal{E}_s$. Esta prova matemática é dada em [35], e obtemos que:

$$P_{erro} \approx \frac{1}{\pi} \text{sen}^{-1}(\sqrt{\mathcal{E}_s}), \quad (3.3)$$

ou, alternativamente, o erro da energia é dado por:

$$\mathcal{E}_s = \text{sen}^2(\pi P_{erro}). \quad (3.4)$$

Daí vem que reduzindo $\mathcal{E}_s$, o P_{erro} é também reduzido. Ou seja, a probabilidade de erro em detectar os falsos *zero-crossing* (falsos positivos) ou ignorar os verdadeiros *zero-crossing* (falsos negativos) é menor.

Até aqui tratamos do problema do truncamento do operador LoG contínuo, entretanto para implementá-lo num ambiente de processamento de imagens devemos aproximá-lo por uma máscara discreta w_s . Os elementos de w_s são obtidos amostrando a função LoG contínua numa matriz discreta quadrada, onde tais elementos são armazenados no formato de ponto flutuante de dupla precisão. Temos que w_s é dado por:

$$w_s = 1 + 2\lceil l \rceil = 1 + 2\lceil \mu_s \sigma \rceil, \quad (3.5)$$

onde μ_s é um fator de parametrização invariante com a escala σ no domínio espacial, e $\lceil x \rceil$ arredonda para o inteiro mais próximo de x .

Dada a equação (3.5) acima, outro cuidado deve ser tomado para uma correta escolha do tamanho da máscara w_s , a fim de evitar o problema de subamostragem ou *aliasing* da função LoG. Para evitar este problema de subamostragem deve-se limitar os valores

mínimos e máximos de σ para uma dada imagem $N \times N$. Este limite para as imagens orbitais estudadas ($N \approx 256$), e admitindo $P_{\text{erro}} = 0,1\%$ é obtida abaixo.

Fig. 3.2. Erro da energia no domínio espacial.

Se $P_{\text{erro}} = 0,1\%$, $\epsilon_s = 9,9 \times 10^{-6}$ pela equação (3.4), $\mu_s \approx 3,8$ por inversão numérica da equação (3.1) ou pela Fig. 3.2. Tomando μ_f (um fator de parametrização invariante com a escala σ no domínio da frequência) igual à μ_s , $\mu_f \approx 3,8$. Segundo o desenvolvimento matemático em [35] temos que:

$$\frac{\mu_f N}{\pi N - 2} < \sigma < \frac{N - 3}{2\mu_s}, \quad (3.6)$$

substituindo os valores $N = 256$, $\mu_f = \mu_s = 3,8$ na equação (3.6) temos:

$$1,22 < \sigma < 33,3. \quad (3.7)$$

E substituindo $\mu_s = 3,8$ na equação (3.5), o tamanho da máscara LoG w_s é obtido pela equação (3.8) abaixo:

$$w_s = 1 + 2\lceil 3,8\sigma \rceil \quad (3.8)$$

Uma heurística é comumente empregada para a determinação do tamanho da máscara LoG multiplicando por três a distância d_{zc} entre os pontos de *zero-crossing* no domínio espacial ($\approx 8,5\sigma$) [84]. Este valor é próximo ao obtido pela equação (3.8) e, conseqüentemente, implica num erro de detecção dos *zero-crossing* de aproximadamente 0,1%.

Para o caso da detecção dos EOM, limitamos os valores de σ para os quais a distância d_{zc} entre os pontos de *zero-crossing* no domínio espacial (p. 27, Fig. 3.1) seja menor que o menor eixo dos EOM, isto é, $3,0 \text{ mm}$ ou aproximadamente 8 pixels. Vem que:

$$d_{zc} = 2\sqrt{2}\sigma \approx 8 \Rightarrow \sigma = 2,83 \quad (3.9)$$

Dadas as equações (3.7) e (3.9), vem que o domínio de σ para o nosso estudo será,

$$1,22 < \sigma < 2,83 \quad (3.10)$$

O fator de correção κ_d que corrige a anisotropia da máscara LoG discreta é dado por:

$$\kappa_d = -\frac{1}{w_s^2} \sum_{x=-((w_s-1)/2)}^{((w_s-1)/2)} \sum_{y=-((w_s-1)/2)}^{((w_s-1)/2)} \nabla^2 G_\sigma(x, y) \quad (3.11)$$

Outras alternativas têm sido empregadas para garantir que o resultado da soma de todos elementos da máscara LoG discreta seja igual à zero [85]. Entretanto, tais métodos distorcem a forma do LoG no intuito de preservar a propriedade de isotropia (p. 1, ver nota de rodapé) da função LoG e, conseqüentemente, produzem implementações inexatas do LoG.

Avaliação do desempenho do LoG na detecção dos EOM

Uma medida de desempenho ZC_{erro} , baseada na correta classificação do *zero-crossing* do LoG, foi escolhida para comparar os resultados obtidos com a máscara LoG implementada em relação ao erro teórico esperado P_{erro} . Neste experimento utilizamos várias imagens CT coronal da órbita (Fig. 3.3a). O algoritmo de busca dos *zero-crossing* utilizado produz um mapa de contornos fechados (imagem binária) que representa as bordas dos objetos da imagem convolvida com a máscara LoG. Este mapa de contornos tem a mesma resolução espacial da imagem convolvida [24]. ZC_{erro} é computado pela equação (3.12), abaixo:

$$ZC_{erro} = \frac{\text{falsos positivos} + \text{falsos negativos}}{|N \times N|}. \quad (3.12)$$

onde os falsos positivos são os falsos *zero-crossing* detectados e falsos negativos são verdadeiros *zero-crossing* não detectados. $|N \times N|$ indica o número total de pixels do mapa de contornos.

Um exemplo do mapa de contornos obtidos do *zero-crossing* da imagem convolvida com o LoG é apresentado na Fig. 3.3b.

Fig. 3.3. Mapa de contornos de uma imagem CT coronal da órbita.

A medida de desempenho ZC_{erro} foi realizada em três escalas diferentes ($\sigma = 1,0$, $\sigma = 2,0$, $\sigma = 3,0$) com valores ímpares para w_s variando de 3 a 31. Tomamos $w_s = 49$ como referência (mapa de contorno estável) para o cálculo de ZC_{erro} nas diferentes escalas σ .

A Fig. 3.4a mostra que a qualidade da classificação do *zero-crossing* pela máscara LoG é degradada quando w_s é reduzido. O primeiro gráfico (Fig. 3.4a) mostra quanto maior σ , maior será o w_s e o desempenho do detector LoG será melhor (ZC_{erro} pequeno) quando w_s aumenta. O segundo gráfico (Fig. 3.4b) mostra ZC_{erro} versus μ_s sobreposto ao erro teórico esperado P_{erro} . É evidente que a curva $\sigma = 1,0$ produziu um melhor desempenho quando comparado com σ maiores. Entretanto, $\sigma = 1,0$ está fora dos limites impostos pelas equações (3.7 e 3.10) e, conseqüentemente, podem existir erros associados a este mapa de contornos devido aos efeitos de truncamento e amostragem.

Fig. 3.4. Erro na detecção do *zero-crossing*.

O $\sigma = 1,0$ foi utilizado no experimento por ser um parâmetro de escala usualmente escolhido para o LoG. Também no segundo gráfico (Fig. 3.4b), os valores experimentais tendem para o erro teórico P_{erro} quando aumentamos μ_s .

Neste experimento para o $P_{erro} = 0,1\%$, $\sigma = 2,0$ apresentou melhores resultados que $\sigma = 3,0$, e ainda atendeu a condição de limite dada pela equação (3.10). Logo é possível afirmar, com base na teoria apresentada acima, que a melhor escolha de escala para detecção dos EOM é $\sigma = 2,0$.

Como extensão deste estudo da implementação de uma máscara LoG ótima, a Fig. 3.5 ilustra os erros quando usamos $\sigma > 2,0$ para detecção dos EOM. A máscara LoG com $\sigma = 2,0$ e $w_s = 49$ foi usada como referência para a computação dos erros (falsos positivos e falsos negativos). No gráfico apresentado na Fig. 3.5, os resultados são apresentados para σ inteiros variando de 3 a 14. Os resultados em cada escala σ foram normalizados pelo número total de *zero-crossing* detectados para $\sigma = 2,0$. De acordo com este gráfico, o aumento de σ não resulta em aumento de falsos positivos (bordas deslocadas) como afirmam trabalhos anteriores [86], [87], [88]. De fato os resultados obtidos aqui [10] provam o contrário, ou seja, a diminuição de falsas bordas e aumento de falsos negativos (bordas perdidas). Segundo a nossa revisão bibliográfica, este resultado é inédito e não explorado anteriormente.

Fig. 3.5. Erro normalizado na detecção do *zero-crossing* para $\sigma > 2,0$.

3.2.2 O método de segmentação

A segmentação dos EOM utilizando o *zero-crossing* enfrenta vários problemas, dentre eles destacam-se: o excesso de segmentação e a falha na detecção das bordas dos EOM

conectados à parede orbital, ou quando estes músculos estão conectados entre si (Fig. 3.6).

$$\sigma = 2,0, w_s = 17$$

Fig. 3.6. Falhas na detecção dos EOM usando o *zero-crossing*.

A fim de superar as dificuldades apontadas acima, a morfologia matemática foi investigada com o propósito de promover uma solução efetiva capaz de extrair os EOM da imagem convolvida com o LoG. Neste sentido alguns algoritmos foram propostos ao longo da pesquisa [7], [8], [10]. Estes algoritmos utilizavam ainda o *zero-crossing* para autenticar a presença de bordas, a partir das quais um usuário (um médico especialista) selecionava no mapa de contornos as localizações dos EOM (Fig. 3.7).

Fig. 3.7. A primeira solução para extração dos EOM.

O diagrama de blocos (Fig. 3.8) resume as operações realizadas para obter a imagem final apresentada na Fig. 3.7.

Fig. 3.8. Diagrama de blocos da primeira solução para extração dos EOM.

Note que antes de gerar o mapa de contornos pelo zero-crossing ($\sigma = 2,0$, $w_s = 17$), efetua-se uma abertura pelo elemento estruturante em forma de disco plano com raio $r = 2$ (Fig. 3.9). Esta operação elimina os zero-crossing provenientes de baixas variações de tons de cinza ou ruídos. Portanto, um mapa de contorno é obtido como resultado dos zero-crossing vindos, sobretudo, de bordas potencias. Uma vez gerado o mapa de contornos, o usuário pode selecionar os EOM com o auxílio do mouse (Fig. 3.7, seleção dos EOM). Então, estas regiões selecionadas são preenchidas observando-se a conectividade N_8 (os oito primeiros vizinhos dos pixels marcados pelo usuário). A Fig. 3.9, $r = 1$ mostra estes oito vizinhos de um dado pixel central p . Logo após, os contornos destas regiões são suavizados por meio de uma operação de fechamento seguida da abertura pelo elemento estruturante disco, $r = 1$ (Fig. 3.9).

Fig. 3.9. Elemento estruturante em forma de disco plano.

Embora o algoritmo acima descrito apresente bons resultados na segmentação dos EOM, buscamos um método que ofereça uma segmentação mais rápida e que explore ainda mais as potencialidades da morfologia matemática. Neste caso, partindo da imagem pré-processada pelo LoG, desenvolvemos um método de segmentação dos EOM (MSEG) que:

- requer mínima supervisão do usuário; e
- capaz de quantificar todas as estruturas segmentadas em apenas alguns segundos (e.g. ~12 segundos nas imagens com dimensão 256×256 e 8 bits em tons de cinza).

O diagrama de blocos é apresentado (Fig. 3.10) a seguir. Na seção seguinte (p. 39, seção 3.3.4), os resultados de desempenho da segmentação e de um estudo quantitativo utilizando este MSEG são apresentados.

Fig. 3.10. Diagrama de blocos do MSEG.

A Fig. 3.10 apresenta o fluxo de processamento do MSEG. A fim de facilitar a compreensão deste método, o diagrama foi dividido em dois módulos principais:

- detecção da órbita: a região de interesse (ROI); e
- detecção dos EOM.

Logo cada módulo do MSEG é descrito, indicando-se quando necessário os valores típicos usados nos experimentos.

O módulo de detecção da órbita

Este módulo limita o processo de segmentação dos EOM dentro da região orbital, onde os EOM estão realmente localizados.

Inicialmente, o fechamento por reconstrução da imagem original é realizado aplicando-se um número n finito de iterações recursivas de erosões em f_e pelo elemento estruturante cruz, $r = 1$ (Fig. 3.11), condicionada à imagem original. A imagem f_e é obtida dilatando a imagem original por um elemento estruturante disco com raio $r = 50$ (p. 34, Fig. 3.9). O número de iterações é automaticamente computado fazendo

n igual à maior dimensão da imagem original, e.g., se uma imagem tem dimensão 256×380 , $n = 380$.

Fig. 3.11. Elemento estruturante cruz.

A operação de fechamento mostrou-se uma poderosa aliada no processo de extração da órbita, esta operação uniformiza as regiões orbitais e vizinhas que serão segmentadas usando a técnica de limiarização (ver p. 6). O usuário escolhe o limite máximo $I_{\max}$, pois o limite mínimo $I_{\min}$ foi fixado nos experimentos num valor igual à 30 (o maior valor possível para o limite máximo é 255). A Fig. 3.12 ilustra essa seqüência de operações descrita acima. Em casos particulares em que a detecção possa falhar, um módulo externo é disponibilizado para permitir o traçado manual da ROI pelo usuário.

Fig. 3.12. Seqüência inicial da detecção da órbita.

No bloco filtros morfológicos binários, aplicamos uma sequência de operadores morfológicos na imagem binária (Fig. 3.12, limiarização) para extrair as órbitas, como pode ser visto na Fig. 3.13. Logo, passo a passo efetuam-se as operações abaixo:

- faça um fechamento por um elemento estruturante disco com raio $r = 20$ (p. 34, Fig. 3.9);
- inverta esta imagem e elimine os objetos que tocam a borda da imagem; e
- elimine pequenas estruturas.

Fig. 3.13. Sequência final da detecção da órbita.

O módulo de detecção dos EOM

Neste módulo retomou-se uma idéia anteriormente vista no primeiro algoritmo proposto (p.34, Fig. 3.8). Uma abertura é realizada numa imagem convolvida pelo LoG f_{LoG} ($\sigma = 2,0$, $w_s = 17$). Entretanto usaremos aqui a abertura por reconstrução, pois esta é mais fiel à preservação da forma original das estruturas. Logo, aplicou-se esta operação em f_{LoG} seguindo os passos abaixo:

- erodir f_{LoG} ; e
- dilatar o resultado por n iterações condicionada à imagem original.

Neste caso para erodir f_{LoG} usou-se o elemento estruturante cruz, $r = 15$. Esse elemento estruturante é conseguido por meio de 15 sucessivas adições de Minkowski [42], [38] num arranjo 4-conexo (ver Fig. 3.11, $r = 1$). O pixel central $p(x, y)$ tem quatro vizinhos compartilhando suas arestas: $p(x+1, y)$, $p(x-1, y)$, $p(x, y+1)$ e $p(x, y-1)$. As dilatações foram realizadas usando o elemento estruturante cruz, $r = 1$ (p. 36, Fig. 3.11).

Em sequência, um usuário escolhe o limite máximo $l_{\max}$ para o intervalo de limiarização. Nos experimentos realizados, um valor típico para este parâmetro foi 110.

No bloco filtros morfológicos binários, pequenas estruturas e artefatos devido ao PVE (e.g. borda da órbita) na imagem binária (Fig. 3.14) são removidos aplicando-se uma abertura usando o elemento estruturante cruz, $r = 1$ (Fig. 3.11), e removendo os objetos conectados de vizinhança 4 (N_4) com área menor que 10 pixels. Em seguida, os contornos podem ser suavizados aplicando-se um fechamento pelo elemento estruturante disco, $r = 1$ (Fig. 3.9). Os resultados destas operações são ilustrados na Fig. 3.14 abaixo.

Fig. 3.14. Ilustração da detecção dos EOM.

O MSEG descrito acima foi implementado no ambiente MATLAB [24] em conjunto com o *toolbox* de morfologia matemática da SDC [25]. A Fig. 3.15 ilustra exemplos de telas de resultados e o painel de controle do aplicativo.

Fig. 3.15. O Aplicativo.

3.3 A quantificação 3D da musculatura extraocular

A questão da quantificação do grau de deformação dos EOM adquire importância fundamental no estudo do quadro evolutivo da orbitopatia de Graves, principalmente identificando os pacientes com risco de desenvolvimento de neuropatia óptica. Logo, desenvolvemos neste trabalho ferramentas de software, tal como o aplicativo de segmentação semi-automática (Fig. 3.15), que podem auxiliar os médicos na identificação e classificação destes pacientes.

Num estudo quantitativo, realizado por Silvestrini [12], mediu-se manualmente os eixos vertical e horizontal dos EOM em filmes CT coronal da órbita. A fim de estabelecer uma comparação entre os resultados deste estudo manual e os resultados utilizando o MSEG (p. 45, seção 3.4), os EOM foram medidos em seis fatias no sentido antero-posterior (Fig. 3.16), conforme [12]. A fatia de referência é definida quando o rebordo orbital lateral está totalmente formado, então as fatias do estudo são tomadas a partir desta posição a cada 3 mm sucessivamente.

Fig. 3.16. Exemplo de um estudo dos EOM por CT.

Note bem que a fatia de referência não entra no estudo e a posição tomográfica coronal é um dado importante no estudo da deformação dos EOM. Por isso, cada fatia foi nomeada segundo a sua posição em relação à fatia de referência. Por exemplo, P3 – primeira fatia localizada a 3 mm atrás da fatia de referência; P6 – segunda fatia localizada a 6 mm da fatia de referência, e assim por diante até P18 – última fatia situada a 18 mm da fatia de referência, numa posição próxima ao ápice orbital. Neste estudo quantitativo a *taxa de ocupação dos EOM na órbita* (TO) é dada pela equação (3.13), abaixo:

$$TO = \frac{\text{Volume dos EOM}}{\text{Volume Orbital}}, \quad (3.13)$$

onde o *Volume dos EOM* é a soma dos volumes binários de cada EOM segmentado pelo MSEG (p.35, Fig. 3.10). Igualmente, o *Volume Orbital* é também computado pelo volume binário da órbita obtido pelo MSEG.

Visualização 3D dos EOM por superfícies

O estudo quantitativo dos EOM é valioso no que diz respeito à identificação e a classificação de casos que possam levar o paciente à cegueira. Porém, este nada instrui sobre a forma e as relações anatômicas dos EOM. Deste modo, uma solução de visualização 3D torna-se necessária. No intuito de suprir esta carência, uma aplicação de visualização 3D baseada em SR foi desenvolvida. No Capítulo 4 é apresentada uma solução baseada em VR que produz imagens tridimensionais com qualidade de detalhamento dos tecidos mole e ósseo.

Logo, implementou-se um algoritmo de SR (Fig. 3.17) em Tcl/Tk utilizando as bibliotecas de funções do VTK [26].

Fig. 3.17. Algoritmo de SR.

O algoritmo de SR proposto usa as imagens binárias obtidas pelo MSEG. Ou seja, o usuário utiliza o aplicativo (p. 39, Fig. 3.15) para gerar o volume binário. Em seguida, este volume é classificado em 5 grupos:

1. MVS – musculatura vertical superior (RS e CS);
2. MVI – musculatura vertical inferior (RI);
3. MH – musculatura horizontal (RL e RM);
4. GO – globo ocular; e
5. NO – nervo óptico.

Os passos posteriores são comumente empregados em algoritmos de SR bastante conhecidos como, por exemplo, os utilizados no laboratório da *GE – R&D Center, New York*, e no *Brigham and Women's Hospital Surgical Planning Lab, Boston* [26]. O algoritmo de SR (Fig. 3.17) gera um modelo 3D dos EOM que permite interação com o usuário. É possível realizar operações de rotação e magnificação nos EOM com o auxílio do mouse. Na seção 3.4, os resultados obtidos por este algoritmo são ilustrados.

Erro nas medidas dos modelos 3D

Neste ponto é preciso abordar sobre o erro nas medidas a partir de modelos 3D poligonais dos EOM (Fig. 3.17). Naturalmente que estimar erros pressupõe a determinação do valor exato da medida de interesse (e.g. volume). E, neste caso, uma estimativa de erro pode ser realizada em fantoms matemáticos 3D, uma vez que estes possuem formas bem definidas cujas medidas são exatas e determinadas teoricamente.

Dessa forma os erros foram avaliados sob dois aspectos, são eles:

1) *Amostragem* : cinco fantoms foram obtidos a partir de uma função 3D contínua de uma esfera de raio $r = 10 \text{ mm}$. Para isso, seções transversais ou fatias binárias, igualmente espaçadas, foram tomadas ao longo de um dos eixos desta função e, então, usadas para criar os modelos 3D com o algoritmo de SR proposto (Fig. 3.17). No primeiro modelo, as fatias binárias estão $0,5 \text{ mm}$ afastadas uma das outras. No segundo modelo, estas estão posicionadas a $1,0 \text{ mm}$ de distância uma das outras. Dessa forma, os espaçamentos entre as fatias do terceiro, quarto e quinto modelo foram $1,5 \text{ mm}$, $2,0 \text{ mm}$, $2,5 \text{ mm}$, respectivamente. Os volumes dos cinco modelos foram computados e os erros avaliados (p. 49, seção 3.4).

2) *Triangulação*: recordando o que foi dito na p. 14, seção 2.2, os algoritmos de SR reconstroem todo o volume como uma coleção de primitivas geométricas. O algoritmo de SR proposto no trabalho (Fig. 3.17) é baseado no *marching cubes*, ou seja, usa triângulos como primitivas geométricas. Portanto, o número de triângulos do modelo 3D determina tanto a qualidade de modelamento do volume quanto o tempo de processamento do algoritmo. Uma das vantagens dos algoritmos de SR é a interação com o modelo 3D gerado. Isto se traduz em permitir ao usuário realizar sobre o modelo 3D rápidas operações de rotação, magnificação, *rendering*, etc. Nos casos em que o número de triângulos é excessivo, esta vantagem é bastante limitada. Logo, o objetivo é também fornecer um modelo 3D que possa representar o volume acuradamente com um número reduzido de triângulos. Contudo este balanço não é fácil, pois uma redução de triângulos (*decimate*, ver [26]), além de afetar a qualidade do modelo, aumenta o erro nas medidas destes. Para verificar a influência da redução de triângulos nos modelos 3D gerados e estabelecer um fator de redução que não introduza ainda mais erros nas medidas, um segundo experimento foi realizado. Logo, três esferas idênticas ($r = 10,0 \text{ mm}$) foram modeladas com diferentes números de triângulos, as medidas de volume e superfície de cada uma foram computadas e os respectivos erros avaliados (p. 49, seção 3.4).

O algoritmo usado para o cálculo do volume e da superfície é baseado no teorema da divergência [89], [90], [91].

O teorema da divergência diz que uma dada superfície S limita um volume V a equação (3.14), abaixo:

$$\iiint_V \nabla \cdot \vec{F} dV = \iint_S \hat{n} \cdot \vec{F} dS, \quad (3.14)$$

onde $\hat{n}$ é o vetor unitário perpendicular à superfície S , apontando para fora do volume em cada ponto de S , $\nabla \cdot \vec{F}$ é a divergência de $\vec{F}$ e $\vec{F}(x, y, z)$ é um campo vetorial diferenciável em V . Logo, escolhendo $\vec{F}$ de modo que $\nabla \cdot \vec{F} = 1$ (e.g. $\vec{F} = (\vec{x}, \vec{y}, \vec{z})/3$), a integral do volume se torna o volume da região, assim:

$$V = \iint_S \frac{(n_x x + n_y y + n_z z)}{3} dS. \quad (3.15)$$

Uma vez que S é uma coleção de primitivas geométricas, a integral de superfície pode ser aproximada por uma soma de Riemann. Portanto, dada uma superfície S formada por m polígonos, onde o i -ésimo polígono tem uma área A_i , uma normal $\hat{n}_i = (\hat{u}_i, \hat{v}_i, \hat{w}_i)$ e contém um ponto $c(x_i, y_i, z_i)$. Este ponto pode ser escolhido como um vértice ou centróide. Temos que o volume V é aproximadamente:

$$V = \sum_{i=1}^m \frac{(x_i u_i + y_i v_i + z_i w_i) \times A_i}{3}. \quad (3.16)$$

Outra alternativa para a escolha de $\vec{F}$ é $\vec{F} = (a\hat{x}, b\hat{y}, c\hat{z})$, onde $a, b, c \in \mathbb{Z}^+$ e $a + b + c = 1$. Uma solução para os valores de a, b, c pode ser baseada na excentricidade k do volume. Esta idéia de excentricidade foi utilizada neste trabalho, ou seja o $\vec{F}$ escolhido para o cálculo do volume foi $\vec{F} = (k_x \hat{x}, k_y \hat{y}, k_z \hat{z})$, onde:

$$k_x = \sum_{i=1}^m \frac{\hat{x} \cdot \hat{u}_i}{m}, \quad k_y = \sum_{i=1}^m \frac{\hat{y} \cdot \hat{v}_i}{m}, \quad k_z = \sum_{i=1}^m \frac{\hat{z} \cdot \hat{w}_i}{m}, \quad (3.17)$$

onde $k_x + k_y + k_z = 1$.

Um experimento num modelo 3D dos EOM é realizado comparando o volume binário a partir das fatias segmentadas pelo MSEG com o volume calculado pelo teorema da divergência, acima descrito (p. 49, seção 3.4).

3.4 Resultados

Esta seção apresenta: os resultados de desempenho da segmentação realizada pelo MSEG (p. 35, Fig. 3.10); um estudo quantitativo envolvendo 4 grupos de pacientes (um grupo normal e três grupos de Graves); e os resultados qualitativos e quantitativos dos modelos 3D obtidos a partir de fantoms matemáticos e de um dado volumétrico real dos EOM.

Resultados de desempenho do MSEG

Avaliou-se a acurácia da segmentação dos EOM, correlacionando os resultados do MSEG com o traçado manual de dois observadores num conjunto de imagem CT da

órbita de cinco pacientes (3 normais e 2 Graves). Neste experimento, os dois observadores pintaram as regiões correspondentes aos EOM em cada fatia com o auxílio do mouse. Enquanto realizavam a tarefa de segmentação, também, podiam magnificar as regiões de interesse (e.g. bordas dos EOM). Cada observador segmentou no total 109 regiões dos EOM. As áreas envolvidas de cada EOM foram computadas e comparadas aos pares entre os dois observadores e o MSEG, como mostra abaixo a Tabela 3.1.

Tabela 3.1. Correlação R entre as áreas medidas manualmente e pelo MSEG.

	R	REGRESSÃO LINEAR	NÚMERO DE MEDIDAS
GRUPO CONTROLE			
Observador 1 <i>versus</i> MSEG	0,93	$1,02x - 0,07$	61
Observador 2 <i>versus</i> MSEG	0,96	$0,97x + 0,18$	61
Observador 1 <i>versus</i> Observador 2	0,94	$1,02x - 0,08$	61
GRUPO GRAVES			
Observador 1 <i>versus</i> MSEG	0,79	$0,88x + 1,00$	48
Observador 2 <i>versus</i> MSEG	0,89	$0,93x + 0,67$	48
Observador 1 <i>versus</i> Observador 2	0,85	$0,80x + 1,14$	48

O valor de correlação R foi calculado entre as áreas segmentadas pelos observadores e pelo MSEG [92], mostrando uma boa proximidade dos valores de R para todos os casos (R entre 0,85 a 0,96). A Tabela 3.1 mostra que as áreas dos EOM determinadas pelo MSEG são comparáveis às obtidas pelos observadores e bem ajustadas por uma regressão linear (inclinação da reta entre 0,80 a 1,02). A Fig. 3.18 apresenta um gráfico de correlação das medidas manuais *versus* as medidas automáticas realizadas pelo MSEG. Os resultados mostram que estas medidas são quase idênticas (correlação $R = 0,92$ e regressão linear $0,96x - 0,49$).

Fig. 3.18. Gráfico de correlação entre a segmentação manual e automática.

Estudo quantitativo dos EOM

Uma avaliação quantitativa foi realizada num conjunto de 33 pacientes subdivididos em quatro grupos diferentes (1 grupo normal e 3 grupos Graves), são eles:

1. Grupo normal: 5 pacientes voluntários sem problema oculomotor (e.g. estrabismo).
2. Grupo Graves sem miopatia: 15 pacientes com orbitopatia de Graves, que apresentam aumento dos EOM sem presença de problema oculomotor.
3. Grupo Graves com miopatia: 5 pacientes com orbitopatia de Graves, que apresentam ambos fatores – aumento dos EOM e problema oculomotor.
4. Grupo Graves com neuropatia óptica: 8 pacientes com orbitopatia de Graves, que apresentam lesão no nervo óptico causada pelo exagerado aumento dos EOM.

As medidas deste estudo foram realizadas segundo a metodologia descrita na seção 3.3, p. 39. Os dados de cada um dos grupos foram analisados, primeiro, isoladamente por meio de análise de variância multifatorial (ANOVA) [93] com dois fatores: músculo e posição tomográfica coronal. Em seguida, os quatro grupos foram comparados diretamente por uma ANOVA – Kruskal-Wallis com o fator taxa de ocupação dos EOM na órbita TO. O nível de significância dos testes ANOVA foi de 0,05.

Análise de variância – fator músculo

Os 4 grupos foram analisados e os seus resultados são apresentados na Fig. 3.19, como um diagrama de caixa (*Box & Whiskers*). As linhas horizontais na caixa indicam os valores de 25%, 50% (mediana) e 75% percentis das medidas. O símbolo quadrado dentro da caixa representa o valor médio. Os símbolos acima e abaixo da barra de erro indicam os valores máximo e mínimo, respectivamente.

Fig. 3.19. Gráfico das distribuições das áreas dos EOM nos grupos – fator músculo.

O teste ANOVA para o fator músculo não apresentou diferenças estatisticamente significantes para nenhum dos grupos. Contudo nos grupo Graves, os músculos RM e RI apresentaram-se bastante aumentados em relação aos outros EOM.

Os EOM do grupo Graves com neuropatia óptica sofreram as maiores deformações com relação ao grupo normal.

Análise de variância – fator posição tomográfica coronal

A Fig. 3.20 mostra os resultados das distribuições das medidas de área dos EOM com relação ao fator posição tomográfica coronal.

Fig. 3.20. Gráfico das distribuições das áreas nos grupos – fator posição tomográfica coronal.

O fator posição tomográfica coronal foi altamente significativo no grupo normal miopatia ($F = 5,61$ e $P < 0,05$)*, indicando claramente a forma fusiforme dos EOM. O fator posição tomográfica coronal também foi significativo ($F = 2,317$ e $P < 0,05$) no grupo Graves sem miopatia, pois os EOM ainda apresentam a forma fusiforme característica do grupo normal. Nos grupos Graves com miopatia e com neuropatia óptica é fácil notar o aumento expressivo das dimensões dos EOM, principalmente, nas regiões próximas ao ápice da órbita (P12, P15 e P18).

* P significa que para uma dada significância qual o valor que o teste rejeita a hipótese nula H_0 . Os valores de F representam a razão entre as variâncias das medidas nos grupos e total numa distribuição normal.

Análise de variância – fator taxa de ocupação

Os quatro grupos foram comparados diretamente por meio da medida de taxa de ocupação dos EOM na órbita TO, como mostra a Fig. 3.21.

Fig. 3.21. Gráfico das distribuições do fator taxa de ocupação do EOM na órbita nos grupos.

A análise de variância entre os quatro grupos indicou diferenças estatisticamente significantes ($H = 18,11$ e $P < 0,05$). O TO médio para o grupo de Graves com neuropatia óptica (34,29%) correspondeu a aproximadamente cinco vezes o TO médio do grupo normal (7,27%), como mostra a Tabela 3.2.

Tabela 3.2. Diferenças estatisticamente significantes entre os grupos usando taxa de ocupação dos EOM na órbita TO.

	GRUPO	MEDIANA	25%	75%
CONTROLE	1	7,27	6,61	8,18
GRAVES SEM MIOPATIA	2	17,96	11,50	23,28
GRAVES COM MIOPATIA	3	22,51	19,54	29,55
GRAVES COM NEUROPATIA ÓPTICA	4	34,29	21,01	41,31
COMPARAÇÃO	DIFERENÇAS	Q	P<0,05	
1×2	11,93	2,39	Não	
1×3	18,00	2,94	Sim	
1×4	22,47	4,07	Sim	
2×3	6,06	1,21	Não	
2×4	10,54	2,49	Não	
3×4	4,47	0,81	Não	

Resultados qualitativos do modelo 3D

Um dado volumétrico CT da cabeça, $256 \times 256 \times 93$ fatias axiais com 12 bits e tamanho do voxel igual à $0,8 \times 0,8 \times 1,5 \text{ mm}^3$, foi segmentado pelo MSEG (p. 35) e renderizado superficialmente utilizando o algoritmo de SR proposto (p. 41). Os resultados são ilustrados na Fig. 3.22^{cor} abaixo.

Fig. 3.22^{cor}. Renderização superficial dos EOM e parte do crânio: (a) vista inferior, e (b) vista superior.

Resultados quantitativos do modelo 3D

A Tabela 3.3 mostra os resultados de erro da medida do volume devido à amostragem nos cinco modelos de esferas produzidas segundo a metodologia descrita na p.41.

Tabela 3.3. Erro devido à amostragem.

AMOSTRAGEM	VOLUME CALCULADO $\times 10^3 \text{ mm}^3$	ERRO
0,5 mm	4,185	0,06%
1,0 mm	4,177	0,25%
1,5 mm	4,180	0,18%
2,0 mm	4,146	1,00%
2,5 mm	4,123	1,56%
Volume teórico da esfera $V_e = 4,188 \times 10^3 \text{ mm}^3$		

A Fig. 3.23 ilustra o caso de redução do número de triângulos no modelo 3D de três esfera idênticas de raio $r = 10 \text{ mm}$. A Tabela 3.4 apresenta os erros das medidas de volume para este caso.

Fig. 3.23. O erro nas medidas de volume e superfície nos modelos 3D de esferas devido à redução de triângulos.

Tabela 3.4. Erro devido à redução de triângulos.

NÚMERO DE TRIÂNGULOS	VOLUME $\times 10^3 \text{ mm}^3$ (ERRO)	SUPERFÍCIE $\times 10^2 \text{ mm}^2$ (ERRO)
50	4,173 (0,36%)	12,543 (0,18%)
150	4,187 (0,02%)	12,563 (0,02%)
500	4,188 (0%)	12,566 (0%)

Volume teórico da esfera $V_e = 4,188 \times 10^3 \text{ mm}^3$, superfície teórica da esfera $S_e = 12,566 \times 10^2 \text{ mm}^2$

Os resultados acima eram esperados, pois confirmam a acurácia do cálculo de volume pelo teorema da divergência quando temos primitivas geométricas (triângulos) cada vez menores.

Um experimento num modelo 3D dos EOM avalia o erro do volume medido pelo teorema da divergência (volume 3D) em relação ao volume binário a partir das fatia segmentadas pelo MSEG (volume 2D), como mostra a Tabela 3.5 abaixo.

Tabela 3.5. Erro do volume num modelo 3D dos EOM.

	VOLUME 3D $\times 10^3 \text{ mm}^3$	VOLUME 2D $\times 10^3 \text{ mm}^3$	ERRO
MVS	1,06	1,68	36,41%
MVI	0,64	0,90	27,92%
MH	2,53	3,37	24,86%
NO	1,08	1,35	19,89%
GO	13,19	13,57	2,5%

A Fig. 3.24 ilustra a renderização SR do GO neste experimento e os respectivos valores do volume e excentricidade k .

Fig. 3.24. Modelo 3D do globo ocular.

As discussões e conclusões sobre estes resultados serão apresentadas no Capítulo 5, p. 75. No próximo capítulo trataremos sobre o efeito de volume parcial (PVE).

Capítulo 4

Renderização Volumétrica na Presença do Efeito de Volume Parcial

4.1 Introdução

Nos últimos dez anos, o PVE tem sido estudado no contexto de segmentação de imagem [16], [17], [18], [19], [20], [21], [22]. Entretanto, pouca atenção tem sido dada quando este está relacionado à renderização de objetos [17]. Comparado ao tamanho do detalhe da estrutura que desejamos visualizar numa imagem médica, o tamanho dos voxels definido pelo equipamento de imagem é normalmente maior. Conseqüentemente, um valor agregado das propriedades físicas dos múltiplos tecidos contidos no voxel é atribuído a este voxel, especialmente nas interfaces dos tecidos. Este fenômeno é geralmente referido ao *efeito de volume parcial* (PVE). A qualidade do resultado da segmentação e da imagem tridimensional (3D) de estruturas anatômicas em CT (e outras modalidades) é normalmente afetada pelo PVE. Em *rendering* volumétrico (VR), assim como em *rendering* superficial (SR), especialmente em aplicações médicas, uma das tarefas mais difíceis é visualizar tecidos específicos em relação às estruturas vizinhas [50], [58]. Ambas técnicas têm vantagens e desvantagens e ambas não são imunes ao PVE. No SR falsas estruturas podem ser criadas o que pode obscurecer as estruturas interiores se o PVE não for devidamente trabalhado. No VR utilizando cores, falsas estruturas podem aparecer com a mesma cor das estruturas de interesse. Logo, estas falsas estruturas confundem os observadores e os fazem chegar a conclusões

erradas. A Fig. 4.1 ilustra as regiões afetadas pelo PVE numa fatia de CT da cabeça de um paciente. A Fig. 4.1b mostra os voxels com PVE que imitam os voxels contendo tecido mole.

Fig. 4.1. Ilustrações das regiões afetadas pelo PVE numa fatia de um dado volumétrico CT da cabeça: (a) imagem original, e (b) regiões com PVE significantes (setas brancas).

Essas regiões de PVE têm *número CT* (tom de cinza) idêntico ao tecido mole, o que contribui para o obscurecimento das estruturas de tecido mole vizinhas. A Fig. 4.2^{cor} mostra um VR da cabeça utilizando uma simples função de classificação trapezoidal que exibe ambos tecidos, mole e ósseo. As linhas cinza que aparecem no crânio são devido aos falsos voxels de tecido mole nas interfaces entre osso e gordura. As mesmas estruturas falsas ocorrem no interior do crânio nas interfaces do osso-par-ar e do osso-para-gordura. A pele, que também tem número CT idêntico ao tecido mole, reduz a visibilidade das renderizações do osso e do tecido mole. Os métodos propostos neste capítulo têm como objetivo superar esta dificuldade e, então, gerar uma imagem 3D com qualidade superior de detalhamento.

Fig. 4.2^{cor}. VR da Fig. 4.1a mostrando a musculatura facial e o crânio. As linhas cinzas no crânio são ocorrências de falsos tecidos moles devido ao PVE.

Apresentamos dois *métodos de classificação dos voxels com PVE* (MCLA) na seção 4.2 para superação do PVE em imagens de CT. Estes métodos utilizam um conceito fundamental conhecido como *escala* [94]. A escala indica o tamanho da estrutura local que é determinado em cada voxel numa dada imagem baseado somente num critério de homogeneidade dos tons de cinza. A premissa básica é que regiões de escalas pequenas representam regiões potenciais de PVE. Os Algoritmos para os dois MCLA são apresentados. Também apresentamos na seção 4.3, um método para remoção da pele e o seu respectivo algoritmo. Na seção 4.4 apresentamos os resultados dos nossos métodos em imagens clínicas. Validações qualitativa e quantitativa destes métodos também são apresentadas, e em ambas validações usamos imagens clínicas de CT e fantoms matemáticos. As discussões e conclusões sobre estes resultados serão apresentadas no Capítulo 5, p.75.

4.2 Classificando voxels com efeito de volume parcial

Notação e definições

Nos referimos a uma imagem volumétrica adquirida como uma *cena*, e a representamos por um par $\mathbf{C} = (C, f)$ onde $C = \{c \mid -b_j \leq c_j \leq b_j \text{ para todo } b \in Z_+^3\}$, Z_+^3 é o conjunto de 3-tupla, chamado *voxel*, de inteiros positivos, f é uma função cujo domínio é $\mathbf{C}$, chamado *domínio da cena*, e cujo contra-domínio é um conjunto de inteiros $[L; H]$. Chamamos $\mathbf{C}$ uma *cena binária* se o contra-domínio de f é $\{0,1\}$. A *esfera digital*

(ou simplesmente *esfera*) de raio r centrado em qualquer voxel c em C é o conjunto $B_r(c) = \{d \in C \mid |c - d| \leq r\}$. Para qualquer conjunto X , usamos $|X|$ para representar a sua cardinalidade.

Apresentamos dois métodos nesta tese para identificar e suprimir voxels com PVE. O primeiro método, chamado o método de *medida de fração* (FM) examina regiões específicas no domínio da cena onde os valores de escala são pequenos. Nestas regiões em cada voxel c , examinando uma vizinhança cujo tamanho é de novo determinado pela escala de c , uma fração é estimada para cada tipo de tecido dentro de c . No segundo método, um princípio teórico de informação chamado *princípio da incerteza* (UP) [23], também guiado pelos valores de escalas, e um critério associado são usados para estimar a fração de cada tecido nos voxels localizados em regiões de incerteza alta. Desde que o conceito de escala forma a base destes métodos, descreveremos brevemente seu princípio e um algoritmo para estimar a escala logo abaixo. Em seguida, apresentamos uma descrição dos métodos FM e UP nas seções 4.2.1 e 4.2.2, respectivamente. Ambos métodos aceitam como entrada uma cena e retornam como saída uma cena modificada onde os voxels afetados pelo PVE estão identificados e suprimidos. Qualquer método SR ou VR pode ser subsequente aplicado à cena resultante.

Escala

Nesta seção descrevemos o algoritmo que produz a escala do objeto $f_s(c)$ para qualquer c numa dada cena. Esse conceito e o algoritmo foram relatados pela primeira vez em [94].

Para uma esfera $B_r(c)$ de raio r centrada em c , definimos uma fração, $FO_r(c)$, que indica a fração do conjunto dos voxels no limite da esfera cujos tons de cinza são suficientemente uniformes com o tom de cinza de c , pela equação (4.1) abaixo:

$$FO_r(c) = \frac{\sum_{d \in B_r(c) - B_{r-1}(c)} W_\psi(|f(c) - f(d)|)}{|B_r(c) - B_{r-1}(c)|}, \quad (4.1)$$

onde $W_x(x)$ é a função de relação nebulosa que corresponde ao predicado “ x é pequeno”. Nesta tese uma função Gaussiana não-normalizada com média zero e desvio padrão σ_ψ é utilizada para W_ψ . O σ_ψ é um parâmetro de homogeneidade estimado tomando todo domínio da cena C ; ver [23] para detalhes. O algoritmo para *estimar a escala do objeto* (OSE) é sumarizado abaixo:

Algoritmo OSE

Entrada: $C, c \in C, W_\psi$, um valor de limiarização t_s .

Saída: Uma cena $C_s = (C, f_s)$ representando os valores de escala da cena C .

início

para cada $c \in C$ *faça*

atualizar $r = 1$;

enquanto $FO_r(c) \geq t_s$ *faça*

incremente r para $r + 1$;

fim-enquanto;

atualizar $f_s(c)$ para r ;

salvar $f_s(c)$;

fim-para;

fim

O algoritmo acima aumenta iterativamente o raio r da esfera em uma unidade, iniciando em $r = 1$, e confere $FO_r(c)$, a fração do objeto contendo c que é limitada pela borda da esfera. A primeira vez que essa fração fica abaixo do valor de limiarização t_s , consideramos que a esfera atravessou um objeto de uma região diferente daquela que c pertence. Conforme [94], nós usamos $t_s = 0,85$. De forma simplificada, $f_s(c)$ é o raio da maior esfera centrada em c onde dentro desta esfera os voxels são suficientemente homogêneos. A Fig. 4.3 ilustra uma fatia da cena de escala C_s a partir de uma cena de CT da cabeça. Os valores de tons de cinza representam os valores de escala $f_s(c)$. Os voxels mais claros indicam os valores de escala mais altos.

Fig. 4.3. Ilustração da cena de escala: (a) original, e (b) cena de escala.

4.2.1 O método de medida da fração

A idéia básica deste método é que as regiões internas dos objetos são mais ou menos homogêneas, e conseqüentemente, os voxels nestas regiões têm valores de escala grandes. Estas regiões não são afetadas pelo PVE e nem são de interesse no processo de *rendering*. Por outro lado, os voxels com valores de escala pequenos estão localizados em regiões de borda nebulosa e de interface dos tecidos. Conseqüentemente, os valores de escala $r = f_s(c)$ associado ao voxel c numa dada cena $\mathbf{C} = (C, f)$ pode nos guiar na identificação dos voxels afetados pelo PVE. Além disso, as frações dos diferentes tipos de tecidos dentro de cada voxel podem ser estimadas examinando as intensidades dos voxels dentro da esfera $B_r(c)$ centrada em c , como veremos. Tomemos τ denotando o tipo de tecido. Em imagens de CT, estamos principalmente interessados em tecido mole (st) e osso (bn), logo temos que $\tau \in \{st, bn\}$. Embora os métodos apresentados aqui possam ser estendidos para os casos de misturas acima de dois tecidos, iremos nos restringir ao caso somente destes dois tecidos. Para um valor de escala fixo ρ , e para qualquer voxel $c \in C$ numa dada cena $\mathbf{C} = (C, f)$ tal que $f_s(c) \leq \rho$, definimos a fração do tecido $\tau \in \{st, bn\}$ contido em c como sendo

$$F_\rho^\tau(c) = \frac{\sum_{d \in B_\rho(c)} W_\tau(f(d))}{|B_\rho(c)|}. \quad (4.2)$$

Onde $W_\tau(x)$ é uma função de relação nebulosa que expressa a relação entre os valores de tons de cinza x e o percentual (fracionalidade) contido de tecido τ . Desde que os objetos de interesse em CT são compostos dos tecidos mole e ósseo. De acordo, o algoritmo apresentado abaixo determina apenas estas frações. Um tratamento mais geral considerando todos as possíveis interfaces é, certamente, possível.

Algoritmo FM

Entrada: Uma cena $\mathbf{C} = (C, f)$, ρ , W_τ , $\mathbf{C}_S = (C, f_s)$, constantes t_{st} e t_{bn} .

Saída: $\mathbf{C}_{FM} = (C, f_{FM})$.

início

atualizar $f_{FM}(c) = f(c)$ todos os voxels $c \in C$;

para todos os voxels $c \in C$ tal que $f_s(c) \leq \rho$ faça

    Compute $F_\rho^{st}(c)$ e $F_\rho^{bn}(c)$;

    se $F_\rho^{st}(c) < t_{st}$ e $F_\rho^{bn}(c) < 1$ e $f(c) < t_{bn}$ então

        atualizar $f_{FM}(c) = 0$;

    fim-se;

    fim-para;

fim

No algoritmo acima t_{st} e t_{bn} são valores fixos de limiar. t_{st} representa um valor de limiar na fração do tecido mole, e t_{bn} é um limiar mínimo no valor de tom de cinza do osso. Assumimos que W_τ seja uma função Gaussiana (Fig. 4.4). Sua média e desvio padrão são estimados por treinamento, que consiste de um operador pintar apropriadas regiões de tecidos mole e ósseo em fatias da cena CT, determinando dessa maneira os valores de média e desvio padrão nessas regiões. O valor de ρ é fixado em 5. Os resultados pioram se $\rho \gg 5$. Nós usamos $t_{st} = 0,3$ e $t_{bn} = 1100$ (em imagens de CT monocromáticas de 12 bits com intervalo $[0; 4095]$).

$$W_{st}(f(c)) = e^{-\frac{(f(c)-m_{st})^2}{2\sigma_{st}^2}}, \quad \sigma_{st} > 0 \quad W_{bn}(f(c)) = \begin{cases} e^{-\frac{(f(c)-m_{bn})^2}{2\sigma_{bn}^2}}, & \sigma_{bn} > 0 \\ 1, & f(c) > m_{bn} \end{cases}$$

Fig. 4.4. Funções Gaussianas W_τ : (a) aplicada ao tecido mole, e (b) aplicada ao osso.

4.2.2 O método baseado no princípio da incerteza

A base deste método é o seguinte postulado proposto em [23] relacionado com os achados do ótimo valor de limiar: “Em qualquer imagem adquirida, voxels com incerteza mais alta ocorrem próximos à borda do objeto.”. A classe de incerteza $U_\rho(c)$ em qualquer voxel c numa dada cena $\mathbf{C} = (C, f)$ é dada por

$$U_\rho(c) = -\sum_{\tau} P_{\rho}^{\tau}(c) \ln P_{\rho}^{\tau}(c), \quad (4.3)$$

onde $P_{\rho}^{\tau}(c)$ é a probabilidade que um voxel com um tom de cinza $f(c)$ pertença à classe de tecido τ , e é dada por

$$P_{\rho}^{\tau}(c) = \frac{F_{\rho}^{\tau}(c)}{\sum_{\tau} F_{\rho}^{\tau}(c)}. \quad (4.4)$$

A Fig. 4.5 mostra, para uma fatia de CT da cabeça, as regiões onde a incerteza é mais alta e mais baixa. Claramente, nas bordas nebulosas, a maior parte dos voxels tem incertezas altas.

Fig. 4.5. Ilustração das regiões de incerteza (regiões mais claras) em bordas nebulosas numa fatia de CT da cabeça: (a) incerteza mais alta. (b) incerteza mais baixa.

A idéia básica neste método é identificar os voxels afetados pelo PVE numa dada cena usando o princípio da incerteza e suprimi-los na cena resultante. O algoritmo para o método UP é apresentado abaixo.

Algoritmo UP

Entrada: Uma cena $\mathbf{C} = (C, f)$, ρ , W_τ , $\mathbf{C}_S = (C, f_S)$, constantes t_{st} e t_{bn} .

Saída: $\mathbf{C}_{UP} = (C, f_{UP})$.

início

atualizar $f_{UP}(c) = f(c)$ todos os voxels $c \in C$;

para todos os voxels $c \in C$ tal que $f_S(c) \leq \rho$ faça

    Compute $P_\rho^{st}(c)$, $P_\rho^{bn}(c)$, e $U_\rho(c)$;

    se $U_\rho(c) < t_{st}$ e $P_\rho^{bn}(c) < 1$ e $f(c) < t_{bn}$ então

        atualizar $f_{UP}(c) = 0$;

    fim-se;

    fim-para;

fim

Neste algoritmo, todos os parâmetros são determinados como no algoritmo FM, exceto t_{st} e t_{bn} . t_{st} é fixado em 0,85 e t_{bn} é fixado em 1100. t_{st} se manteve insensível dentro da faixa de valores $[0,6; 0,85]$, como revelou nossos experimentos.

4.3 O método para remoção da pele

Este método remove automaticamente a pele numa cena $\mathbf{C} = (C, f)$ promovendo uma sensível melhora na renderização volumétrica dos tecidos mole e ósseo.

O método utiliza o mapa de probabilidade $P_\rho^{st}(c)$, para todo $c \in C$, de maneira que uma camada fina e externa à pele $\eta(c)$ é obtida por meio de uma procura radial, indo das bordas em direção ao centro em cada fatia da cena. Esta procura é realizada em uma cena binária onde somente os voxels com $P_\rho^{st}(c) < t_{st}$ estão presentes. Em seguida, aplicamos iterativamente n dilatações sucessivas em $\eta(c)$ usando o elemento estruturante 5×5 com todos os pixels do arranjo ativos (ver detalhes na p. 8, seção de morfologia matemática), também conhecido como N_{16} (os dezesseis primeiros vizinhos conectados ao pixel central do arranjo). Após algumas iterações a camada $\eta(c)$ cobrirá toda a região da pele que será removida automaticamente por meio de álgebra booleana. Este método simula uma raspagem, tão profunda quanto se queira, da pele controlada pelo número de n dilatações em $\eta(c)$.

Algoritmo RS

Entrada: Uma cena $\mathbf{C} = (C, f)$, $P_\rho^{st}(c)$, constantes t_{st} e n .

Saída: $\mathbf{C}_{RS} = (C, f_{RS})$.

início

atualizar $i = 0$;

atualizar $f_{RS}(c) = 0$ todos os voxels $c \in C$;

para todos os voxels $c \in C$ tal que $P_\rho^{st}(c) < t_{st}$ *faça*;

atualizar $f_{RS}(c) = 1$;

fim-para;

extrair $\eta(c)$ por procura radial;

enquanto $i < n + 1$ *faça*

dilatar $\eta(c)$;

atualizar i para $i + 1$;

fim-enquanto

atualizar $f(c) = 0$ todos os voxels $c \in \eta(c)$;

fim

4.4 Resultados

Nesta seção apresentamos renderizações volumétricas, antes e depois da aplicação dos métodos de remoção dos voxels com PVE e da pele, em dados de CT de pacientes, como: craniofacial, tronco, joelho e a cabeça da *visible woman* [95]. Um experimento é realizado, envolvendo fantoms matemáticos simulando três níveis de PVE (baixo, médio e alto). Estes fantoms foram criados utilizando objetos geométricos e adicionando borramento usando um filtro Gaussiano e uma componente de ruído. Uma validação quantitativa é feita usando os dados clínicos de CT e os fantoms matemáticos. Todos os resultados demonstram melhora na qualidade de exibição dos tecidos mole e ósseo depois da aplicação dos métodos propostos neste capítulo. Além disso, a retirada da pele revela detalhes finos nas estruturas do tecido mole. A Tabela 4.1 mostra uma descrição dos dados usados neste trabalho.

Tabela 4.1. Descrição dos dados 3D.

DADOS 3D	TAMANHO	TAMANHO DO VOXEL	TONS DE CINZA
CRANIOFACIAL	$307 \times 267 \times 58$	$0,49 \times 0,49 \times 1,50 \text{ mm}^3$	12 bits
JOELHO	$256 \times 256 \times 69$	$0,68 \times 0,68 \times 1,00 \text{ mm}^3$	8 bits
CABEÇA DA <i>VISIBLE WOMAN</i>	$512 \times 512 \times 209$	$0,49 \times 0,49 \times 1,00 \text{ mm}^3$	12 bits
TRONCO	$512 \times 512 \times 230$	$0,68 \times 0,68 \times 3,00 \text{ mm}^3$	12 bits
FANTOM MATEMÁTICO	$512 \times 512 \times 58$	$0,49 \times 0,49 \times 1,50 \text{ mm}^3$	12 bits

Validação qualitativa

A Fig. 4.6 mostra o resultado da remoção dos voxels afetados pelo PVE na fatia mostrada na Fig. 4.1. Os resultados VR do osso e tecido mole para os dados craniofacial, joelho, cabeça da *visible woman* e tronco são apresentados nas Fig. 4.7^{cor}, Fig. 4.8^{cor}, Fig. 4.9^{cor}, e Fig. 4.10, respectivamente. Para comparação, apresentamos também os SR do joelho e da cabeça da *visible woman* nas Fig. 4.11 e Fig. 4.12. Todas renderizações foram criadas usando o algoritmo *shell-rendering* [53] implementado no

3DVIEWNIX [27] e funções de opacidade trapezoidais [68]. As figuras mostram renderizações criadas a partir da cena original sem aplicação de nenhum dos métodos propostos aqui e depois da aplicação destes métodos em diferentes combinações.

Fig. 4.6. Remoção dos voxels com PVE na fatia mostrada na Fig. 4.1: (b) após aplicação do método FM, e (b) após aplicação do método UP.

As secções transversais dos fantoms matemáticos são ilustrados na Fig. 4.13. As Fig. 4.15 e Fig. 4.14^{cor} mostram os resultados após a remoção da pele e dos voxels afetados pelo PVE. Observamos para todas estas figuras que o PVE foi efetivamente suprimido pelos dois métodos. É claramente observado na Fig. 4.14^{cor} que as estruturas mais finas, dificilmente observadas em renderizações criadas antes da remoção da pele e dos voxels afetados pelo PVE, estão consideravelmente bem expostas depois da supressão do PVE. A remoção da pele adicionalmente revela detalhes mais finos e podemos iniciar a identificação de específicas estruturas neuro-musculares e musculares.

Fig. 4.7^{cor}. VR de CT num paciente com anomalia craniofacial. Superior-esquerdo: cena original. Superior-direito: após remoção da pele. Meio-esquerdo: após aplicação do método FM. Meio-direito: após aplicação do método UP. Inferior-esquerdo: após remoção da pele e aplicação do método FM. Inferior-direito: após remoção da pele e aplicação do método UP.

Fig. 4.8^{cor}. VR de CT do joelho. Superior-esquerdo: cena original. Superior-direito: após remoção da pele. Meio-esquerdo: após aplicação do método FM. Meio-direito: após aplicação do método UP. Inferior-esquerdo: após remoção da pele e aplicação do método FM. Inferior-direito: após remoção da pele e aplicação do método UP.

Fig. 4.9^{cor}. VR de CT da cabeça da *visible woman*. Superior-esquerdo: cena original. Superior-direito: após remoção da pele. Meio-esquerdo: após aplicação do método FM. Meio-direito: após aplicação do método UP. Inferior-esquerdo: após remoção da pele e aplicação do método FM. Inferior-direito: após remoção da pele e aplicação do método UP.

Fig. 4.10. VR de CT do tronco: (a) usando a cena original, e (b) após remoção a pele e aplicação do método UP.

Fig. 4.11. SR de CT do joelho. Superior-esquerdo: cena original. Superior-direito: após remoção da pele. Meio-esquerdo: após aplicação do método FM. Meio-direito: após aplicação do método UP. Inferior-esquerdo: após remoção da pele e aplicação do método FM. Inferior-direito: após remoção da pele e aplicação do método UP.

Fig. 4.12. SR de CT da cabeça da *visible woman*. Superior-esquerdo: cena original. Superior-direito: após remoção da pele. Meio-esquerdo: após aplicação do método FM. Meio-direito: após aplicação do método UP. Inferior-esquerdo: após remoção da pele e aplicação do método FM. Inferior-direito: após remoção da pele e aplicação do método UP.

Fig. 4.13. Fantom matemático 3D: (a) secção transversal, e (b) a Fig. 4.13a após adição de três níveis de borramento e ruído (1- nível baixo, 2- nível médio e 3- nível alto).

Fig. 4.14^{cor}. VR dos fantons 3D. Coluna esquerda: após remoção da pele e aplicação do método FM. Coluna do meio: após remoção da pele e aplicação do método UP. Coluna direita: antes da remoção da pele e do PVE.

Fig. 4.15. Secção transversal das regiões de tecido mole mostrados na Fig. 4.14.

Validação quantitativa

Descrevemos aqui um experimento para avaliar o desempenho dos dois MCLA. Desde que os voxels com PVE que introduzem os artefatos nos fantoms são conhecidos, a extensão da remoção destes pode ser quantificada. Uma validação quantitativa similar é realizada nos dados clínicos de CT, onde um operador traça cuidadosamente uma ROI excluindo os voxels com PVE em imagens segmentadas previamente. Seja $\mathbf{C}^{t_l, t_h} = (C, f^{t_l, t_h})$, uma cena binária resultante da limiarização de $\mathbf{C}$ pelo intervalo de limiar $[t_l, t_h]$. Isto é, para qualquer $c \in C$, temos

$$f^{t_l, t_h}(c) = \begin{cases} 1, & \text{se } t_l \leq f(c) \leq t_h, \\ 0, & \text{ao contrário.} \end{cases} \quad (4.5)$$

Dessa forma, definimos a *Figura de Mérito* FOM_x para descrever a acurácia da remoção dos voxels com PVE realizado pelos métodos FM e UP, como veremos a seguir. Logo, para $x = \{\text{FM}, \text{UP}\}$,

$$FOM_x = 1 - \frac{|(\mathbf{C}^{t_l, t_h} - \mathbf{C}_{True}^{t_l, t_h}) XOR (\mathbf{C}^{t_l, t_h} - \mathbf{C}_x^{t_l, t_h})|}{|\mathbf{C}^{t_l, t_h} - \mathbf{C}_{True}^{t_l, t_h}|}, \quad (4.6)$$

onde $|\mathbf{C}^{t_l, t_h} - \mathbf{C}_{True}^{t_l, t_h}|$ é o número de voxels com PVE *verdadeiros*, XOR computa a operação booleana *OU exclusivo* entre duas cenas binárias e $|(\mathbf{C}^{t_l, t_h} - \mathbf{C}_{True}^{t_l, t_h}) XOR (\mathbf{C}^{t_l, t_h} - \mathbf{C}_x^{t_l, t_h})|$ é o número de voxels com PVE *falsos* (erro do método). Para o método x , FOM_x indica o grau de concordância entre os voxels com

PVE *verdadeiros* capturados em $(\mathbf{C}^{t_l, t_h} - \mathbf{C}_{True}^{t_l, t_h})$ e os voxels com PVE *classificados* em $(\mathbf{C}^{t_l, t_h} - \mathbf{C}_x^{t_l, t_h})$ nos possíveis intervalos $[t_l, t_h]$ na cena $\mathbf{C}$. $\mathbf{C}_{True}$ é a cena 3D onde o operador traça a ROI excluindo os voxels com PVE. $\mathbf{C}_x$ é a cena 3D cujos voxels com PVE foram removidos pelo método x . Em nossa validação quantitativa, usamos oito cenas divididas em: cinco CT de pacientes craniofaciais, e três fantoms matemáticos (Fig. 4.14).

A Tabela 4.2 mostra que, em média, mais de 98% dos voxels afetados pelo PVE foram removidos por ambos os métodos. O teste H_0 de hipótese nula [93] das diferenças pareada entre os valores médios da FOM_x , $|\bar{\delta}|$, foi computado e mostrou que não existe diferença estatisticamente significativa entre os dois MCLA. O teste H_0 apresentou os seguintes resultados abaixo:

$$|\bar{\delta}| = 0,006, t = -1,071, P = 0,302.$$

Entretanto, o método UP apresentou resultados um pouco melhores que o método FM, especialmente em imagens mais degradadas pelo PVE.

Tabela 4.2. Média, desvio padrão (SD) e valores mínimos da FOM_x , sendo $x = \{\text{FM}, \text{UP}\}$.

	FM			UP		
	media	SD	media	media	SD	SD
	mínimo			mínimo		
Fantom (n=3)	0,982	0,019	0,956	0,990	0,010	0,979
Cabeça (n=5)	0,992	0,011	0,972	0,997	0,004	0,988
Total	0,988	0,014	0,956	0,994	0,007	0,979

Capítulo 5

Conclusões

A questão da quantificação e visualização 3D adquire importância fundamental na identificação dos pacientes com orbitopatia de Graves com risco de desenvolvimento de neuropatia óptica – lesão do nervo óptico podendo levar o paciente à cegueira. Dessa forma, o objetivo desta tese foi desenvolver novos métodos de segmentação, quantificação e visualização 3D para um estudo mais acurado das deformações dos EOM na orbitopatia de Graves. Além disso, contribuímos com novos métodos que efetivamente localizam e suprimem os voxels com PVE, e também removem a pele que causa obscurecimento nas renderizações 3D de estruturas de tecidos mole e ósseo.

Apresentamos e avaliamos um MSEG no Capítulo 3 e o utilizamos num estudo quantitativo envolvendo 33 pacientes (5 normais e 28 pacientes com orbitopatia de Graves). Propomos também um método SR para os EOM. No experimento conduzido, o MSEG proposto realizou medidas quase idênticas àsquelas obtidas pelo traçado manual realizado por dois observadores (correlação $R = 0,92$ e regressão linear $0,96x - 0,49$), além de superar as principais dificuldades do traçado manual: subjetividade e tempo consumido na segmentação. Um operador consegue, sem muito esforço, segmentar e quantificar as áreas dos EOM numa fatia em poucos segundos (e.g. ~ 12 segundos nas imagens com dimensão 256×256 e 8 bits em tons de cinza). Na p. 39, a Fig. 3.15 mostra o aplicativo de segmentação semi-automática, desenvolvido para o ambiente MATLAB, que incorpora o MSEG desenvolvido nesta tese.

Durante os estudos da avaliação do desempenho do LOG na detecção dos EOM [10], conduzimos experimentos que revelaram achados inéditos como: o aumento de σ não resultou num aumento de bordas deslocadas nas imagens de órbitas estudadas[10].

Acreditamos que o fato se deve a nossa rigorosa determinação do tamanho da máscara e implementação do filtro digital LOG. Os experimentos indicaram também que o $\sigma = 2,0$ é a melhor escala para a detecção dos EOM. O estudo quantitativo dos EOM revelou que os músculos RM e RI nos grupos de Graves apresentam-se bastante aumentados em relação aos EOM normais. Estes resultados estão de acordo com estudos clínicos realizados anteriormente [96], [97]. A natureza fusiforme dos EOM é observada apenas nos grupos normais e Graves sem miopatia. Os grupos Graves com miopatia e Graves com neuropatia óptica apresentam os EOM bastante aumentados, principalmente na região apical da órbita onde o nervo óptico é mais susceptível à compressão pelo EOM. A medida de *taxa de ocupação dos EOM na órbita* (TO) feita nos quatro grupos apresentou o maior valor no grupo Graves com neuropatia óptica, TO=34,3%. Este valor é quase cinco vezes maior que o grupo normal, TO=7,3%.

É preciso deixar claro que as considerações quantitativas supracitadas não podem ser tomadas como anatômicas. Os planos dos cortes coronais de CT da órbita não são perpendiculares aos planos horizontais. Na realidade, a cabeça do paciente é estendida em grau variável e o corte é aproximadamente paralelo ao perfil da face. Como a obliquidade da musculatura vertical não é igual à horizontal, a inclinação do corte coronal resultante varia segundo o músculo considerado. Além disso, se levarmos em conta que o plano de corte também não é rigorosamente igual para todos os pacientes fica claro que diferenças em relação à área “anatômica” existem e estão relacionadas ao cosseno do ângulo formado entre as direções do músculo e do corte coronal [12].

O erro no volume dos EOM medido a partir do modelo 3D, em comparação com a estimativa do volume calculado a partir das fatias segmentadas pelo MSEG, está relacionado com a resolução de aquisição do dado volumétrico e, subseqüentemente ao PVE. Este erro pode apresentar diferenças acima dos 20%, como foi visto no exemplo da Tabela 3.5, p. 51. Demonstramos que a amostragem e a redução de triângulos devem ser escolhidas com cuidado e, para garantir medidas mais acuradas e uma visualização 3D de melhor qualidade, desenvolvemos dois MCLA: FM e UP para superação do PVE.

No método FM, a fração de cada tecido (osso e tecido mole) num voxel v é estimada levando-se em consideração os tons de cinza da vizinhança de v . O tamanho dessa vizinhança é dada pelo valor de escala em v . A escala em qualquer voxel é o raio da maior esfera, centrada em v , em que os tons de cinza são homogêneos. Funções

Gaussianas são usadas para a computação das frações. Esta informação de mistura é efetiva na remoção dos voxels com PVE.

O método UP é baseado no seguinte postulado [23]: “*Em qualquer imagem adquirida, voxels com incerteza mais alta ocorrem próximos à borda do objeto.*”. As probabilidades dos tons de cinza pertencerem a determinados tipos de tecidos são utilizadas para estimar a classe de incerteza de cada voxel v . O valor da incerteza e a informação sobre os tecidos vizinhos indicam os voxels com PVE que devem ser removidos. Uma vez que a escala é computada, ambos métodos são de certa forma simples e fáceis de implementar dentro de qualquer programa de *rendering* volumétrico.

Desenvolvemos também um método para remover a pele utilizando a morfologia matemática. Com isto, as renderizações 3D dos tecidos mole e ósseo são muito mais visíveis e estruturas finas como: veias e artérias podem ser visualizadas com maior riqueza de detalhes.

O efeito combinado dos três métodos resulta numa melhora na qualidade das renderizações e nos detalhes que estas renderizações exibem

Concluimos com os resultados apresentados no Capítulo 4 que os MCLA efetivamente removem, em média, mais de 98% dos voxels afetados pelo PVE, como revelaram os nossos experimentos em imagens clínicas de CT e utilizando fantoms matemáticos. Embora o método UP apresente melhores resultados qualitativo e quantitativo, principalmente em imagens mais degradadas pelo PVE, não existe diferença estatisticamente significativa entre os dois métodos.

As renderizações 3D devem ser usadas com cuidado na radiologia em vista dos artefatos demonstrados nesta tese e que são provenientes, principalmente, do PVE. A imagem tridimensional é uma tecnologia excitante que está realizando importantes contribuições na medicina e em outras áreas do conhecimento. Entretanto, são ainda muitos os desafios a serem superados, e nessa jornada surgirão novos métodos e novas aplicações que atenderão a necessidades por enquanto ainda imprevistas.

6 Anexos Coloridos

Este anexo disponibiliza em cores as figuras marcadas com a palavra sobrescrita *cor* (e.g. Fig. 3.22^{cor}) que aparecem ao longo do texto da tese em preto-e-branco.

7 Referências Bibliográficas

-
- [1] Souza A.D.A., Ruiz E.E.S., Cruz A.A.V., Coelho R.P., A novel approach to analyze palpebral outline by digital image processing, *Medical & Biological Engineering & Computing*, 35 (1): 161, 1997.
  - [2] Souza A.D.A., Uma nova abordagem para analisar e quantificar a morfologia da fenda palpebral por meio de processamento de imagem, *Dissertação de Mestrado*, Faculdade de Filosofia, Ciências e letras de ribeirão Preto, USP, 1997.
  - [3] Cruz A.A.V., Coelho R.P., Baccega A., Lucchezi M., Souza A.D.A., Ruiz E.E.S., Digital image processing measurement of upper eyelid contour in Graves disease and congenital blepharoptosis, *Ophthamology*, 105 (5): 913-918, 1998.
  - [4] Souza A.D.A., Ruiz E.E.S., Cruz A.A.V., The palpebral fissure morphology segmentation and measurement by digital image processing using a Laplacian-of-Gaussian operator, *IEEE Engineering in Medicine and Biology*, 19 (1): 114-119, 2000.
  - [5] Souza A.D.A., Udupa J.K., Saha P.K., Volume rendering in the presence of partial volume effects, *SPIE Proc: Medical Imaging 2002* (accepted).
  - [6] Firbank M.J., Harrison R.M., Williams E.D., Couthard A., Measuring extraocular muscles volume using dynamic contours, *Magnetic Resonance Imaging*, 19 (2): 257-265, 2001.
  - [7] Souza A.D.A., Ruiz E.E.S., Cruz A.A.V., Segmentação dos músculos extraoculares usando a morfologia matemática associado ao operador LoG, *Anais do IV FNCTS - Fórum Nacional de Ciência e Tecnologia em Saúde*, p. 465-466, 1998.
  - [8] Souza A.D.A., Ruiz E.E.S., Cruz A.A.V., Digital image analysis of extraocular muscles using the mathematical morphology, *Invest Ophthalmol Vis Sci*, 40 (4): 26, 1999.

-
- [9] Souza A.D.A., Ruiz E.E.S., Fast and accurate detection of extraocular muscles borders using mathematical morphology, *Chicago 2000 World Congress on Medical Physics and Biomedical Engineering: Medical Physics*, 27 (6): 1412, July 23-28, 2000.
  - [10] Souza A.D.A., Ruiz E.E.S., Optimal filter based on the Laplacian of Gaussian associated to shape-analysis edge detection for orbit images, *LASTED International Conference on Signal and Image Processing (SIP'2000)*, Las Vegas – Nevada, November 20-23, 2000.
  - [11] Guimarães F.C., Rubin P.A.D., Cruz A.A.V., Quantification of extraocular muscles (EOMs) from coronal CT scans of different subtypes of Graves' orbitopathy, *ARVO Proc*, April 1996.
  - [12] Silvestrini M.C.B.T., Quantificação tomográfica coronal da musculatura extraocular de pacientes com orbitopatia de Graves sem estrabismo e/ou neuropatia óptica, *Dissertação de Mestrado*, Faculdade de Medicina de Ribeirão Preto, USP, 1998.
  - [13] Knapp P., Special types of muscle anomalies associated with Graves' disease, *Ophthalmology*, 86: 2081-2084, 1979.
  - [14] Feldon S.E., Weiner J.M., Clinical significance of extraocular muscle volumes in Graves' ophthalmopathy, *Arch Ophthalmol*, 100: 1266-1269, 1982.
  - [15] Hallim E.S., Fedon S., Graves' ophthalmopathy: I simple CT estimates of extraocular muscle volume, *British Journal of Ophthalmology*, 72: 674-677, 1988.
  - [16] Sato Y., Westin C., Bhalerao A., Nakajima S., Shiraga N., Tamura T., Kikinis R., Tissue classification based on 3D local intensity structures for volume rendering, *IEEE Transactions on Visualization and Computer Graphics*, 6: 160-179, 2000.
  - [17] Beier J., Bittner R.C., Hosten N., Troger J., Felix R., Morphological image processing operators: reduction of partial volume effects to improve 3D visualization based on CT data, *Radiologe*, 38: 860-866, 1998.
  - [18] Santiago P., Gage H. D., Statistical-models of partial volume effect, *IEEE Transactions on Image processing*, 4: 1531-1540, 1995.

-
- [19] Rusinek H., Noz M. E., Maguire G. Q., Kalvin A., Haddad B., Dean D., Cutting C., Quantitative and qualitative comparison of volumetric and surface rendering techniques, *IEEE Transactions on Nuclear Science*, 38: 659-662, 1991.
  - [20] Heuscher D.J., Vembar M., Reduced partial volume artifacts using computed tomography and an integrating interpolator, *Medical Physics*, 26: 276-286, 1999.
  - [21] Vincken K.L., Koster A.S.E., Viergever M.A., Probabilist segmentation of partial volume voxels, *Pattern Recognition Letters*, 15 (5): 477-484, 1994.
  - [22] Firbank M.J., Harrison R.M., Williams E.D., Coulthard A., Measuring extraocular muscles using dynamic contours, *Magnetic resonance Imaging*, 19 (2): 257-265, 2001.
  - [23] Saha, P. K., Udupa, J. K., Optimum image thresholding via class uncertainty and region homogeneity, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23: 689-706, 2001.
  - [24] *Image Processing Toolbox User's Guide*, The MathWorks, Inc., Natick, MA: 2001.
  - [25] *SDC Morphology Toolbox for MATLAB 5 User's Guide*, SDC Information Systems, Naperville, IL: 2001.
  - [26] Schroeder W.J., Martin K., Lorensen W.E., *The visualization toolkit an object-oriented approach to 3D graphics*, Upper Saddle River, NJ: Prentice Hall, 2nd ed., 1998.
  - [27] Udupa J.K., Odhner D., Samarasekera S., Goncalves R., Iyer K., Venugopal K., Furie S., 3DVIEWNIX: An open, transportable, multidimensional, multimodality, multiparametric imaging software system, *SPIE Proc.*, 2164: 58-73, 1994.
  - [28] Pal N.R., Pal S.K., A review on image segmentation techniques, *Pattern Recognition*, 26: 1277-1294, 1993.
  - [29] Gonzalez R. C., Wintz P., *Digital Image Processing*, Reading, Massachusetts: Addison-Wesley, 1987
  - [30] Russ J. C., *The Image Processing Handbook*, CRC Press, LLC, 1998.
  - [31] Albuquerque Márcio P., Albuquerque Marcelo P., *Processamento de imagens: métodos e análise*, Rio de Janeiro: Centro Brasileiro de Pesquisas Físicas, CAT, 2000. [online] www.cbpf.br/cat/download/publicacoes/pdf/ProcessamentoImagens.PDF

-
- [32] Falcão A.X.F., Leite N.J., *Fundamentos de Processamento de Imagem Digital*, Campinas: Unicamp – IC, 1999. [online]
www.dcc.unicamp.br/~cpg/material-didatico/mo815/9802/curso/index.html
  - [33] Rosenfeld A., *Digital Picture Processing*, London: Academic Press, 1982.
  - [34] Marr D., Hildreth E., Theory of edge detection, *Proc R Soc Lond B*, 207: 187-217, 1980.
  - [35] Gunn S.R., On the discrete representation of Laplacian of Gaussian, *Pattern Recognition*, 32: 1463-1472, 1999.
  - [36] Liu Z., Rangayyan, R. M., Frank C.B., Statistical analysis of collagen alignment in ligaments by scale-space analysis, *IEEE Transactions on Biomedical Engineering*, 38 (6): 580-588, 1991.
  - [37] Matheron G., *Random Sets and Integral Geometry*, New York: Wiley, 1975.
  - [38] Serra J., *Image Analysis and Mathematical Morphology*, London: Academic Press, 1982.
  - [39] Haralick R.M., Sternberg S.R., Zhuang X., Image analysis using mathematical morphology, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-9 (4): 532-550, 1987.
  - [40] Serra J., *Image Analysis and Mathematical Morphology: Theoretical Advances*, vol. 2, London: Academic Press, 1988
  - [41] Banon G.J.F., Barrera J., *Bases da Morfologia Matemática para Análise de Imagens Binárias*, IX Escola de Computação, Recife: UFPE – DI, 1994.
  - [42] Facon J., *Morfologia Matemática: Teoria e Exemplos*, Curitiba: Champagnat, 1996.
  - [43] Brodlie K.W., et al. (eds.), *Scientific Visualization – Techniques and Applications*, Germany: Springer-Verlag, 1992.
  - [44] McCormick B.H., Defanti T.A., Brown M.D., Visualization in scientific computing, *Report of the NSF Advisory Panel on Graphics, Image Processing and Workstations*, 1987.
  - [45] Moorhead II R.J., Zhu Z., Signal Processing aspects of scientific visualization, *IEEE Signal Processing* 12 (5): 20-41, 1995.
  - [46] Special issue on visualization, *IEEE Computer Graphics & Applications*, 18 (4), 1998.

-
- [47] Special issue on visualization, *IEEE Computer Graphics & Applications*, 14 (5), 1994.
  - [48] Special issue on visualization, *IEEE Computer*, 27 (7), 1994.
  - [49] Elvins T.T., A survey of algorithms for volume visualization, *Computer Graphics* 26 (3): 194-201, 1992.
  - [50] Udupa J.K., Herman G., *3D Imaging in Medicine*. Boca Raton, Fla: CRC, 1991.
  - [51] Special issue on Advances in Medical Imaging Technology, *IEEE Engineering in Medicine and Biology*, 19 (5), 2000.
  - [52] Falcão, A.X., Visualização de volume aplicada à área médica, *Dissertação de Mestrado*, Faculdade de Engenharia Elétrica de Campinas, UNICAMP, 1993.
  - [53] Udupa, J.K., Odhner D., Shell rendering, *IEEE Computer Graphics & Applications*, 13 (6): 58-67, 1993.
  - [54] Guo B., A multiscale model for structure-based volume rendering, *IEEE Transactions on Visualization and Computer Graphics*, 1 (4): 291-301, 1995.
  - [55] Malzbender T., Fourier volume rendering, *ACM Transaction on Graphics*, 12 (3): 233-250, 1993.
  - [56] Totsuka T., Levoy M., Frequency domain volume rendering, *Computer Graphics*, 27 (4): 271-277, 1993.
  - [57] Lacroute P., Levoy M., Fast volume rendering using a shear-warp factorization of the view transformation, *Computer Graphics*, 28 (4): 451-458, 1994.
  - [58] Kaufman A., Introduction to volume visualization, in: Kaufman A. (ed.), *Volume Visualization*, p. 1-18, Los Alamitos, CA: IEEE Computer Society Press, 1991.
  - [59] Funchs H., Levoy M., Pizer S.M., Interactive visualization of 3D medical data, *IEEE Computer*, 21 (5): 46-50, 1989.
  - [60] Fuchs H., Optimal surface reconstruction from planar contours, *Communications of the ACM*, 20 (10): 693-702, 1977.
  - [61] Watson D.F., *Contouring: a guide to the analysis and display of spatial data*, Pergamon Press, 1992.

-
- [62] Chen L., Herman G.T., Reynolds R.A., Udupa J.K., Surface shading in cuberille environment, *IEEE Computer Graphics & Applications*, 5 (12): 33-43, 1985.
  - [63] Lorensen W.E., Cline H.E., Marching cubes: a high resolution 3D surface construction algorithm, *Computer Graphics*, 21 (4): 163-169, 1987.
  - [64] Bloomenthal J., Polygonization of implicit surface, *Computer Aided Geometric Design*, 5 (4): 341-355, 1982.
  - [65] Ning P., Bloomenthal J., An evaluation of implicit surface tillers, *IEEE Computer Graphics & Applications*, 13 (6): 33-41, 1991.
  - [66] Nielson G.M., Hanann B., The asymptotic decider: removing the ambiguity in marching cubes, in: *proceeding of Visualization '91*, Los Alamitos, CA: IEEE Computer Society Press, 83-91, 1991.
  - [67] Natarajan B.K., On generating topologically correct isosurfaces from uniform samples, *Technical Report HPL-91-76*, Palo Alto, CA, Software and Systems Laboratory, Hewlett-Packard Company, 1991.
  - [68] Drebin R.A., Carpenter L., Hanrahan P., Volume rendering, *Computer Graphics*, 22 (4): 65-74, 1988.
  - [69] Tide U., Hoehne K., Bomans M., Pommert A., Riemer M. and Wiebecke G., Investigation of medical 3D-rendering algorithms, *IEEE Computer Graphics & Applications*, 10 (2): 41-53, 1990.
  - [70] Ney D. R., Fishman E.K., Magid D., Volume rendering of computed tomography data: principles and techniques, *IEEE Computer Graphics & Applications*, 10 (2): 24-32, 1990.
  - [71] Stytz M.R., Frieder G. and Frieder O., Three-dimensional medical imaging: algorithms and computer Systems, *ACM Computing Surveys*, 23 (4): 423-499, 1991.
  - [72] Levoy M., Hanrahan P., Hoehne K. H., Kaufman A. and Lorensen W., Course notes: volume visualization algorithms and architectures, in: *SIGGRAPH '90*, Dallas, 1990.
  - [73] Levoy M., Display of surface from volume data, *IEEE Computer Graphics & Applications*, 8 (3): 29-37, 1988.

-
- [74] Levoy M., Efficient ray tracing of volume data, *ACM Transaction on Graphics*, 9 (3): 245-261, 1990.
  - [75] Westover L., Footprint evaluation for volume rendering, *Computer Graphics (SIGGRAPH '90)*, 24 (4): 36, 1990.
  - [76] Neigel J.M., Rootman J., Belkin R.I., Nugent R.A., Drance S.M., Beattie C.W., Spinelli J.A., Dysthyroid optic neuropathy, *Ophthalmology*, 95: 1515-1521, 1988.
  - [77] Nianiaris N., Hurwitz J.J., Chen J.C., Wortzman G., Correlation between computed tomography and magnetic resonance imaging in Graves' ophthalmopathy, *Canadian Journal of Ophthalmology*, 29: 9-12, 1994.
  - [78] Rootman J. (Ed.), *Disease of the Orbit*, Philadelphia: J.B. Lippincott Co., 1998.
  - [79] Stiehl S.H., 3-D image understanding in radiology, *IEEE Engineering in Medicine and Biology*, 9 (4): 24-28, 1990
  - [80] Rosenfeld A., Image analysis and computer vision, *Computer Vision Graphics and Image Processing*, 59: 367-404, 1993.
  - [81] Falcão A.X., Udupa J.K., Samarasekera S., Sharma S., Hirsch B. E., Lotufo R.A., User-steered image segmentation paradigms: live wire and live lane, *Graphical, Models and Image Processing*, 60: 233-260, 1998
  - [82] Ruiz E.E.S., Fairhurst M.C., Improved approach to boundary location in two-dimensional echocardiographic images, *IEE Proc Vis. Image process*, 142(2):121-127, 1995.
  - [83] Cline H.E., Lorensen W.E., Kikinis R., Jolesz F., Three-dimensional segmentation of MR images of the head using probability and connectivity, *J Comput assist Tomography*, 14 (6): 1037-1045, 1990.
  - [84] Huertas A., Medioni G., Detection of intensity changes with subpixel accuracy using Laplacian-Gaussian mask, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8 (5): 651-664, 1986.
  - [85] Sonka M., Hlavac V., *Image Processing, Analysis and Machine Vision*, Brooks/Cole Publishing, 2nd ed., 1998.

-
- [86] Koplowitz K., Greco V., On the edge location error for local maximum and zero-crossing detectors, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 16 (12): 1207-1212, 1994.
  - [87] Chen J.S., Medioni G., Detection, localization, and estimation of edges, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11 (2): 191-198, 1989.
  - [88] Clark J.J., Authenticating edges by zero-crossing algorithms, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11 (1): 43-57, 1989.
  - [89] Hughe S.W., Darcy T.J., Maxwell D.J., Saunders J.E., Ruff C.F., Chiu W.S.C., Sheppard R.J., Application of new discret form of Gauss' theorem for measuring volume, *Phy Med biology*, 41(9): 1809-1821, 1996.
  - [90] Eberly D., Lancaster J.L., Alyassin A.M., On gray scale image measurements, II. Surface area and Volume, *CVGIP: Graphical Models and Image Processing*, 53(6): 550-562, 1991.
  - [91] Alyassin A.M., Lancaster J. L., Downs J.H., Fox P.T., Evaluation of new algorithms for the interactive measurement of surface area and volume, *Med Phy*, 21(6): 741-752, 1994.
  - [92] Choy M.M., Jin J.S., Extracting endocardial borders from sequential echocardiographic images, *IEEE Engineering in Medicine and Biology*, 17 (1): 116-121, 1998.
  - [93] Costa Neto P.L.O., *Estatística*, São Paulo: Edgard Blücher, 1977.
  - [94] Saha, P. K., Udupa, J. K., Odhner, D., Scale-based fuzzy connected image segmentation: theory, algorithms and validation, *Computer Vision Image Understanding*, 77: 145-174, 2000.
  - [95] Ackerman M.J., *The Visible Human Project*, National Library of Medicine, Bethesda, MD: 1995. [online] www.nlm.nih.gov
  - [96] Boniuk V., Thyroid disease of the eyelids and orbit. In: Hornblass A., Hanig C.J., *Orbit and Lacrimal System*, vol.2, p. 939-951, Baltimore: Williams & Wilkins, 1990

-
- [97] Feldon S.E., Levin L., Liu S.K., Graves's Ophthalmopathy. Correlation of saccadic eye movements with age, presence of optic neuropathy, and Extraocular muscle volume. *Arch. Ophthalmol.*, 108: 1568-1571, 1990.