



UDESC

UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC
CENTRO DE CIÊNCIAS TECNOLÓGICAS – CCT
CURSO DE MESTRADO EM COMPUTAÇÃO APLICADA

DISSERTAÇÃO DE MESTRADO

**SEGMENTAÇÃO AUTOMÁTICA DE
PULMÕES EM IMAGENS DE
RESSONÂNCIA MAGNÉTICA
BASEADA EM MODELOS ATIVOS**

EMANOELI MADALOSSO

JOINVILLE, 2016

UNIVERSIDADE DO ESTADO DE SANTA CATARINA - UDESC
CENTRO DE CIÊNCIAS TECNOLÓGICAS - CCT
MESTRADO EM COMPUTAÇÃO APLICADA

EMANOELI MADALOSSO

**SEGMENTAÇÃO AUTOMÁTICA DE PULMÕES EM IMAGENS
DE RESSONÂNCIA MAGNÉTICA BASEADA EM MODELOS
ATIVOS DE FORMA**

Dissertação apresentada ao Programa de Pós-Graduação em Computação Aplicada do Centro de Ciências Tecnológicas da Universidade do Estado de Santa Catarina, como requisito para a obtenção do grau de Mestre em Computação Aplicada.

Orientador:

Prof. Dr. Roberto Silvio Ubertino
Rosso Junior

Coorientador:

Prof. Dr. André Tavares da Silva

JOINVILLE

2016

M178s Madalasso, Emanoeli

Segmentação automática de pulmões em imagens de ressonância magnética baseada em modelos ativos de forma /Emanoeli Madalasso. – 2016.

147 p. : il. ; 21 cm

Orientador: Roberto Silvio Ubertino Rosso Júnior

Coorientador: André Tavares da Silva

Bibliografia: 119-123 p.

Dissertação (mestrado) – Universidade do Estado de Santa Catarina, Centro de Ciências Tecnológicas, Programa de Pós-Graduação em Computação Aplicada, 2016.

1. Processamento de imagens (técnicas digitais). 2. Ressonância magnética 3. Morfologia matemática.

I. Rosso Júnior, Roberto Silvio Ubertino. II. Silva, André Tavares da. III. Universidade do Estado de Santa Catarina. Programa de Pós-Graduação em Computação aplicada. IV. Título.

CDD: 006.6 - 23. ed.

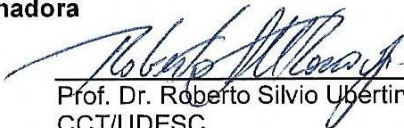
EMANOELI MADALOSSO

**SEGMENTAÇÃO AUTOMÁTICA DE PULMÕES EM IMAGENS
DE RESSONÂNCIA MAGNÉTICA BASEADA EM MODELOS
ATIVOS DE FORMA PARA RECONSTRUÇÃO 4D**


Dissertação apresentada ao Curso de Mestrado Acadêmico em Computação Aplicada como requisito parcial para obtenção do título de Mestre em Computação Aplicada na área de concentração "Ciência da Computação".

Banca Examinadora


Orientador:

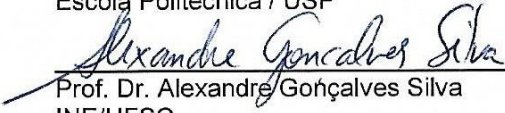

Prof. Dr. Roberto Silvio Ubertino Rosso Junior
CCT/UDESC

Coorientador:


Prof. Dr. André Tavares da Silva
CCT/UDESC

Membros


Prof. Dr. Marcos de Sales Guerra Tsuzuki
Escola Politécnica / USP


Prof. Dr. Alexandre Gonçalves Silva
INE/UFSC

Joinville, SC, 29 de agosto de 2016.

RESUMO

A segmentação de pulmões em imagens de Ressonância Magnética ainda é pouco explorada, uma vez que esta não é a técnica mais comumente utilizada. Entretanto, para aplicações como a reconstrução de modelos quadrimensionais (modelos tridimensionais animados), esta técnica é a mais viável por ser menos prejudicial à saúde, uma vez que sequências de imagens sagitais e coronais são necessárias para cada seção transversal dos pulmões, expondo o paciente a exames mais longos. Estas imagens são adquiridas em respiração livre, estando suscetíveis a borramentos devido a movimentação de todos os órgãos da caixa torácica. Além disso, outro problema é que os pulmões apresentam muitas estruturas internas dependendo da seção transversal, como veias e ramificações bronquiais. Estes fatores contribuem para tornar a segmentação ainda mais difícil. Assim, neste trabalho foram estudadas diversas técnicas de segmentação de órgãos aplicada à pulmões. Dentre estas, o método de Modelos Ativos de Forma se mostrou mais eficiente pois não requer ajustes de parâmetros conforme a sequência, além de sofrer menos interferência de estruturas internas. Desta maneira, foi desenvolvida uma solução baseada em Modelos Ativos de Formas, composta por duas etapas. A primeira etapa constitui a segmentação semiautomática para as imagens de treinamento utilizadas, evitando a segmentação manual de todas as imagens. Devido à grande diferença entre sequências de seções transversais diferentes, foram realizados treinamentos diferenciados. A segunda etapa consiste na identificação e segmentação dos pulmões. Inicialmente Histogramas de Gradientes Orientados são utilizados para definir o treinamento mais apropriado para uma sequência de entrada. Esta mesma técnica é usada para identificar a localização inicial dos pulmões na sequência, iniciando o algoritmo de Modelos Ativos de Forma a partir do local mais apropriado, exigindo menos iterações. A solução proposta foi capaz de segmentar os pulmões de 5 de 6 pacientes da base utilizada de forma totalmente automática. Foi realizada uma validação através da comparação dos resultados obtidos neste trabalho com os resultados obtidos utilizando um método semi automático baseado em morfologia matemática.

Palavras-chaves: Segmentação. Pulmão. ASM. Ressonância magnética.

ABSTRACT

Lungs segmentation in magnetic resonance images is still a little explored area, since this is not the most commonly technique for observing the lungs. However, for applications such as four dimensional reconstruction models (animated three-dimensional models), this technique is more viable because it is less detrimental to health, since sagittal and coronal image sequences are required for each cross-section of the lungs, exposing the patient to longer exams. These images are acquired in free breathing and are susceptible to blurring due to movement of all organs in the chest. Moreover, another problem is that the lungs have many internal structures depending on the cross section of the lungs, as veins and bronchial branching. These factors contribute to make segmentation even harder. Thus, in this work various techniques of organs segmentation were studied and applied to lungs. Among the techniques, the active shape models showed more efficient because it does not require parameter adjustment depending on the sequence, and suffer less interference from internal structures. Thus, a solution based on active shape models was developed, composed by two steps. The first step is the semi-automatic segmentation to the training set images used, avoiding the manual segmentation of all images. Due to the large difference between sequences of different cross sections, different trainings were conducted. The second step is the identification and segmentation of the lungs. Initially histograms of oriented gradients are used to define the most appropriate training for an input sequence. The same technique is used to identify the initial location of the lungs in the sequence, starting the active shape models algorithm from a more appropriated location, requiring fewer iterations. The proposed solution was able to segment the lungs of 5 out of 6 patients from the image dataset in a totally automatic way. The results validation of was performed comparing the results obtained in this work with the results obtained using a semi-automatic method based on mathematical morphology.

Palavras-chaves: Segmentation. Lungs. ASM. MRI.

LISTA DE FIGURAS

Figura 1 – Planos da anatomia humana.	18
Figura 2 – Exemplos de imagens obtidas por Ressonância Magnética. (a) Exemplo de fatia coronal. (b) Exemplo de fatia sagital.	18
Figura 3 – Silhuetas coronais, silhuetas sagitais e intersecção entre silhuetas coronais e sagitais.	19
Figura 4 – Localização do diafragma e movimento de respiração. .	20
Figura 5 – Exemplo de fatia coronal em diferentes momentos do ciclo de respiração.	20
Figura 6 – Exemplos de imagens com diferentes contrastes. (a) Imagem coronal com bom contraste. (b) Imagem coronal com baixo contraste. (c) Imagem sagital com bom contraste. (d) Imagem sagital com baixo contraste. . . .	22
Figura 7 – Exemplos de diferentes formas em pulmões de um mesmo paciente. (a) Imagem coronal do início dos pulmões. (b) Imagem coronal do final dos pulmões. (c) Imagem sagital do início dos pulmões. (d) Imagem sagital do meio dos pulmões.	23
Figura 8 – Exemplo de célula e seu respectivo histograma.	32
Figura 9 – Representação dos histogramas de gradientes orientados de uma imagem. (a) Imagem de entrada. (b) Representação dos histogramas de gradiente da imagem de entrada.	32
Figura 10 – Hiperplano ótimo.	34
Figura 11 – Projeção de dados para plano de maior dimensão. (a) Dados linearmente inseparáveis. (b) Dados projetados em plano de maior dimensão, linearmente separáveis. .	35
Figura 12 – Dilatação e erosão. (a) Imagem original. (b) Imagem dilatada. (c) Imagem erodida.	38

Figura 13 – Abertura e fechamento. (a) Imagem original. (b) Imagem após abertura. (c) Imagem após fechamento. . . .	39
Figura 14 – Tipos de vizinhança. (a) Vizinhança-4 (vertical e horizontal). (b) Vizinhança-4 (diagonal). (c) Vizinhança-8. . .	40
Figura 15 – Crescimento de regiões. (a) Imagem original. (b) Semente fixada no centro da imagem. (c) - (g) Passos intermediários do processo de segmentação. (f) Pulmão segmentado.	41
Figura 16 – Aplicação de PCA em conjunto de amostras em 2 dimensões. p : eixo principal. x pode ser aproximado pelo ponto mais próximo no eixo p : $x \approx x' = \bar{x} + bp$	45
Figura 17 – Reta normal ao ponto p_i	46
Figura 18 – Exemplo de pulmão do conjunto de treinamento com os respectivos perfis de tons de cinza de cada ponto, representados por uma transição abruptada de níveis de cinza.	47
Figura 19 – Retas com tamanho $2m + 1$ (azul) são traçadas para cada ponto da forma média (vermelho).	48
Figura 20 – Combinações possíveis de subvetores.	49
Figura 21 – Pontos da forma média movidos ao longo dos perfis normais (em azul), de acordo com o subvetor que minimiza a distância de Mahalanobis (em verde).	50
Figura 22 – Aplicação de PCA. (a) Forma segmentada antes da aplicação de PCA. (b) Forma segmentada após aplicação de PCA.	50
Figura 23 – Pirâmide de imagem gaussiana.	52
Figura 24 – Formação de imagem 2DST. (a) Empilhamento de sequência de imagens de RM. (b) Corte pelo plano vertical $Q_s(x_s, y_s)$ (c) Imagem 2DST.	56
Figura 25 – Extração de funções respiratórias. (a) Imagem 2DST tratada com operador de Sobel. (b) Espaço de Hough. (c) Funções respiratórias.	57

Figura 26 – Segmentação de imagem usando Gradiente de Sobel: as bordas dos pulmões não ficam evidenciadas devido ao baixo contraste da imagem.	60
Figura 27 – Diagrama das etapas que constituem a geração da base de treinamento.	64
Figura 28 – Exemplos de tipos de fatias sagitais pertencentes a cada um dos 6 grupos: (a) Grupo 1. (b) Grupo 2. (c) Grupo 3. (d) Grupo 4. (e) Grupo 5. (f) Grupo 6.	65
Figura 29 – Exemplos de tipos de fatias coronais pertencentes a cada um dos 6 grupos: (a) Grupo 1. (b) Grupo 2. (c) Grupo 3. (d) Grupo 4. (e) Grupo 5. (f) Grupo 6.	66
Figura 30 – Exemplo de crescimento de regiões com forma de referência para sequência sagital. (a) Imagem sagital segmentada manualmente. (b) Marcador. (c) Região resultante suavizada. (d) Contorno obtido através da região segmentada.	68
Figura 31 – Exemplo de crescimento de regiões com forma de referência para sequência coronal. (a) Imagem coronal segmentada manualmente. (b) Marcador. (c) Região resultante suavizada. (d) Contorno obtido através da região segmentada.	69
Figura 32 – Exemplo do resultado da seleção automática de pontos em imagem coronal.	72
Figura 33 – Diagrama das etapas que constituem a fase de segmentação.	73
Figura 34 – Exemplos de amostras usadas para treino da SVM para localização do pulmão em imagens sagitais: (a), (b) e (c) Amostras positivas. (d), (e) e (f) Amostras negativas.	76
Figura 35 – Exemplos de diferentes formas de pulmões em um mesmo paciente. (a) Fatia inicial. (b) Fatia final do mesmo paciente.	77

Figura 36 – Exemplos de sequências sagitais descartadas: (a) Baixo contraste. (b) Fatia muito próxima das costelas.	82
Figura 37 – Exemplos de sequências coronais descartadas: (a) Baixo contraste. (b) Fatia muito próxima das costelas.	83
Figura 38 – Sentido do perfil de tons de cinza e da reta para busca.	84
Figura 39 – Testes buscando o padrão no sentido de fora para dentro em imagem do nível 1 (imagem ampliada para melhor visualização).	85
Figura 40 – Definição do parâmetro k . (a) Exemplo de escolha de $k = 5$, representando a borda de um pulmão. (b) Mesmo valor de k , representando uma estrutura interna com variação de níveis de cinza semelhante à borda.	86
Figura 41 – Exemplos de segmentação de imagem coronal com diferentes valores de fv : (a) 0,900; 0,905 e 0,910. (b) 0,915; 0,920; 0,925; 0,930; 0,935; 0,940 e 0,945. (c) 0,950; 0,955; 0,960; 0,965 e 0,970. (d) 0,975; 0,980 e 0,985. (e) 0,990. (f) 0,995.	89
Figura 42 – Exemplos de segmentação de imagem sagital com diferentes valores de fv : (a) 0,900. (b) 0,905; 0,910; 0,915; 0,920; 0,925; 0,930; 0,935; 0,940; 0,945 e 0,950. (c) 0,955; 0,960; 0,965; 0,970; 0,975 e 0,980. (d) 0,990. (e) 0,995.	91
Figura 43 – Passo-a-passo da segmentação de uma imagem sagital: (a) Localização dos pulmões. (b) Posicionamento da forma média sobre a janela onde foi feita a detecção. (c) Resultado da primeira iteração do ASM no nível 0. (d) Resultado da segunda iteração do ASM no nível 0. (e) Aplicação de PCA. (Continua).	93
Figura 43 – Passo-a-passo da segmentação de uma imagem sagital: (f) Projeção do resultado do nível 1 no nível 0. (g) Resultado da primeira iteração do ASM no nível 0. (h) Resultado da segunda iteração do ASM no nível 0. (i) Aplicação de PCA - Resultado final. (Continuação). . .	94

Figura 44 – Exemplo de segmentações em imagens sagitais.	95
Figura 45 – Exemplo de segmentações em imagens coronais.	96
Figura 46 – Exemplo de imprecisão rente ao contorno do coração.	97
Figura 47 – Exemplo de imprecisão na segmentação automática de imagem de treinamento.	98
Figura 48 – Exemplos de segmentação incorreta utilizando 2 paci- entes no treinamento. (a) Segmentação resultante. (b) e (c) Exemplos de imagens dos 2 pacientes usados no treinamento.	99
Figura 49 – Exemplos de segmentação incorreta utilizando 4 paci- entes no treinamento. (a) Segmentação resultante. (b) - (e) Exemplos de imagens do treinamento.	100
Figura 50 – Exemplos de segmentação incorreta utilizando 3 paci- entes no treinamento. (a) Segmentação resultante. (b) - (d) Exemplos de imagens do treinamento.	101
Figura 51 – Exemplo de imprecisão em cantos acentuados.	102
Figura 52 – Exemplo de detecção de borda falsa.	102
Figura 53 – Comparação de resultados utilizando segmentação an- terior e sem utilizar segmentação anterior. (a), (c) e (e): Imagens em sequência segmentadas sem utilizar a segmentação anterior. (b), (d) e (f): Imagens em sequên- cia segmentadas utilizando a segmentação anterior.	103
Figura 54 – Variação brusca na posição do diafragma em imagens próximas. (a) Imagem de uma sequência coronal. (b) Próxima imagem da sequência.	104
Figura 55 – Exemplo de segmentações incorretas utilizando o mé- todo de Silva et al. (2014): (a) Imagem sagital. (b) Ima- gem coronal.	105
Figura 56 – Comparação de resultados para imagem sagital. (a) Segmentação de imagem sagital utilizando o método de Silva et al. (2014). (b) Segmentação utilizando o mé- todo proposto. (c) Interseção entre as segmentações (a) e (b).	107

Figura 57 – Comparação de resultados para imagem coronal. (a) Segmentação de imagem coronal utilizando o método de Silva et al. (2014). (b) Segmentação utilizando o método proposto. (c) Interseção entre as segmentações (a) e (b).	109
Figura 58 – Comparação de resultados para imagem sagital utilizando resultados de Silva et al. (2014) no treinamento. (a) Segmentação de imagem sagital utilizando o método de Silva et al. (2014). (b) Segmentação utilizando ASM baseado em treinamento feito com as segmentações de Silva et al. (2014). (c) Interseção entre as segmentações (a) e (b).	111
Figura 59 – Segmentação imprecisa de imagem coronal utilizando as segmentações de Silva et al. (2014) para treinamento do ASM.	112
Figura 60 – Boas segmentações de imagens coronais: (a) Limiarização. (b) Operações Morfológicas. (c) Crescimento de Regiões. (d) <i>Watershed</i> . (e) <i>Snake</i> . (f) <i>Level-set</i>	128
Figura 61 – Segmentações ruins de imagens coronais: (a) Limiarização. (b) Operações Morfológicas. (c) Crescimento de Regiões. (d) <i>Watershed</i> . (e) <i>Snake</i> . (f) <i>Level-set</i>	129
Figura 62 – Segmentações de imagens sagitais: (a) Limiarização. (b) Operações Morfológicas. (c) Crescimento de Regiões. (d) <i>Watershed</i> . (e) <i>Snake</i> . (f) <i>Level-set</i>	130
Figura 63 – Máscaras utilizadas. (a) Máscara gerada pela imagem resultante da limiarização seguida de abertura morfológica e suavização. (b) Máscara usada para dividir os pulmões e eliminar interferência da região da garganta.	130
Figura 64 – Exemplos de resultados da aplicação das máscaras da Figura 63.	131
Figura 65 – Exemplo da aplicação de <i>Snakes</i> Morfológicas de fora para dentro sobre imagens que utilizam máscara.	131

Figura 66 – Aplicação de máscara ineficiente para imagens sagi- tais. (a) Exemplo de máscara obtida por limiarização e suavização sobre imagem sagital. (b) Resultado da adição da máscara obtida com a imagem original. . . .	132
Figura 67 – Paciente 1: Exemplos de cada sequência sagital. . . .	134
Figura 68 – Paciente 1: Exemplos de cada sequência coronal. . . .	136
Figura 69 – Paciente 2: Exemplos de cada sequência sagital (Con- tinua).	137
Figura 69 – Paciente 2: Exemplos de cada sequência sagital (Con- clusão).	138
Figura 70 – Paciente 2: Exemplos de cada sequência coronal. . . .	139
Figura 71 – Paciente 4: Exemplos de cada sequência sagital (Con- tinua).	141
Figura 71 – Paciente 4: Exemplos de cada sequência sagital (Con- clusão).	142
Figura 72 – Paciente 4: Exemplos de cada sequência coronal (Con- tinua).	143
Figura 72 – Paciente 4: Exemplos de cada sequência coronal (Con- clusão).	144
Figura 73 – Paciente 5: Exemplos de cada sequência sagital. . . .	144
Figura 74 – Paciente 6: Exemplos de cada sequência sagital (Con- tinua).	145
Figura 74 – Paciente 6: Exemplos de cada sequência sagital (Con- clusão).	146
Figura 75 – Paciente 6: Exemplos de cada sequência coronal. . . .	147

SUMÁRIO

1	INTRODUÇÃO	17
2	FUNDAMENTAÇÃO TEÓRICA	27
2.1	Aquisição de Imagens Médicas	27
2.2	Detecção dos pulmões	30
2.2.1	Histograma de Gradientes Orientados	31
2.2.2	Máquinas de Vetores de Suporte	33
2.2.2.1	Support Vector Machine multiclases	35
2.3	Segmentação de imagens	36
2.3.1	Morfologia matemática	36
2.3.2	Crescimento de regiões	39
2.3.3	Modelos Ativos de Formas	42
2.3.3.1	<i>Principal Component Analysis</i>	42
2.3.3.2	Modelos Ativos de Forma	43
3	Trabalhos Relacionados	53
4	Método para identificação e segmentação de pulmões	63
4.1	Geração da base de treinamento	63
4.1.1	Separação dos grupos de treinamento	63
4.1.2	Segmentação de imagem de referência	67
4.1.3	Definição do marcador	67
4.1.4	Segmentação do restante da sequência	68
4.1.5	Extração do contorno da região	70
4.1.6	Seleção dos pontos do contorno	70
4.2	Segmentação automática de imagens utilizando <i>Active Shape Models</i>	72
4.2.1	Treinamento	73
4.2.2	Seleção do treinamento	75
4.2.3	Localização dos pulmões	75


4.2.4	Posicionamento da forma média sobre a localização dos pulmões	78
4.2.5	Aplicação do ASM	79
5	Testes e resultados	81
5.1	Testes para definição de parâmetros	81
5.1.1	Definição do sentido de busca	83
5.1.2	Definição da pirâmide de imagens	84
5.1.3	Definição dos parâmetros k , m e fv	85
5.2	Resultados do método proposto	92
5.3	Problemas encontrados	92
5.4	Avaliação dos resultados	104
6	CONCLUSÕES E TRABALHOS FUTUROS	113
	REFERÊNCIAS BIBLIOGRÁFICAS	119
	APÊNDICE A TESTES INICIAIS	125
	APÊNDICE B Segmentações	133
B.1	Paciente 1	133
B.2	Paciente 2	135
B.3	Paciente 4	140
B.4	Paciente 4	140
B.5	Paciente 6	142

1 INTRODUÇÃO

Recentemente, a segmentação de pulmões humanos em imagens estáticas obtidas por Ressonância Magnética (RM) tem sido bastante estudada. Normalmente, estas imagens possuem um bom contraste e menos influência do fluxo sanguíneo, cujo movimento de pulsação pode gerar borramentos na imagem. Já as imagens de RM dos pulmões em movimento, estão mais suscetíveis a este tipo de interferência, o que reduz sua qualidade, sendo apresentados ainda poucos estudos com imagens de pulmões em respiração livre (SILVA et al., 2014). Este tipo de imagem pode ser utilizado no estudo do movimento respiratório, que é de difícil observação, uma vez que os pulmões ficam contidos dentro da caixa torácica e esta não pode ser aberta, pois é ela quem garante sua sustentação. Apesar das dificuldades encontradas para observação do movimento respiratório, seus padrões são de interesse da medicina, pois podem auxiliar na identificação de doenças. Iwasawa et al. (2002), por exemplo, apresentam um estudo que analisa o movimento dos pulmões a partir de imagens sequenciais, detectando a presença de movimentos paradoxais em pacientes com Doença Pulmonar Obstrutiva Crônica (DPOC).


Uma maneira de possibilitar a visualização do movimento respiratório é através da construção de modelos quadridimensionais (4D) dos pulmões, onde tem-se as 3 dimensões espaciais x , y e z e a dimensão temporal. Pode-se construir este modelo é por meio da intersecção de silhuetas dos pulmões, obtidas a partir de diferentes secções transversais do mesmo, chamadas de fatias, nos planos sagital e coronal, exemplificados na Figura 1. A Figura 2 apresenta exemplos de fatias nestes dois planos, obtidas por meio de RM. Já a Figura 3 apresenta a intersecção de várias silhuetas sagitais e coronais, possibilitando a construção de um modelo tridimensional (3D), conforme o trabalho de reconstrução apresentado por Tsuzuki et al. (2009).

Figura 1: Planos da anatomia humana.



Fonte: Adaptado de NATIONAL CANCER INSTITUTE. **Anatomical Terminology.** Disponível em: <<http://training.seer.cancer.gov/anatomy/body/terminology.html>>. Acesso em: 12 Dez. 2015.

Figura 2: Exemplos de imagens obtidas por Ressonância Magnética. (a) Exemplo de fatia coronal. (b) Exemplo de fatia sagital.



Fonte: Hospital Kanagawa (2004-2006)

Figura 3: Silhuetas coronais, silhuetas sagitais e intersecção entre silhuetas coronais e sagitais.




Fonte: Adaptado de Tsuzuki et al. (2009, p. 579)

Para que seja possível representar o movimento dos pulmões, é necessária uma sequência de imagens para cada fatia, adquiridas a partir de exames onde o paciente está em respiração livre, capturando o movimento respiratório. Segundo Abe (2013), o movimento respiratório é composto por componentes passivos e ativos. Os componentes passivos são: ossos, ligamentos e articulações da caixa torácica, enquanto os ativos são os músculos encarregados pelo bombeamento. Dentre estes, o diafragma é o músculo que causa maior alteração de volume nos pulmões, com sua posição podendo variar em até 1,5 cm durante um ciclo de respiração livre, considerando um ciclo, o processo de inspiração seguido da expiração. A Figura 4 mostra a localização do diafragma e como ele se movimenta durante a respiração. Já a Figura 5 mostra exemplos de imagens coronais pertencentes à mesma fatia, em diferentes instantes de tempo, exemplificando a alteração de tamanho percebida nos pulmões devido ao movimento do diafragma em um caso real.


A obtenção das silhuetas dos pulmões é feita através do processo chamado de segmentação, que consiste em subdividir uma imagem em regiões ou objetos que a compõem. Dentro da medicina, ela é amplamente aplicada no processamento de imagens médicas, que po-

Figura 4: Localização do diafragma e movimento de respiração.



Fonte: SÓ BIOLOGIA. **Ventilação pulmonar humana: a ação do diafragma.** Disponível em: <http://www.sobiologia.com.br/conteudos/FisiologiaAnimal/respiracao6.php>. Acesso em: 11 Nov. 2015.

Figura 5: Exemplo de fatia coronal em diferentes momentos do ciclo de respiração.



Fonte: Hospital Kanagawa (2004-2006)


dem ser obtidas de diferentes maneiras, como por Raios-X, Tomografia Computadorizada (TC), Tomografia de Impedância Elétrica (TIE), Ultrassom e RM. Dentre estes métodos de aquisição de imagens, para realizar a reconstrução 4D, destacam-se a TC e RM, que possuem a capacidade de obter imagens de fatias específicas do corpo humano, nos planos sagital e coronal. Dentre estas, a RM tem algumas vantagens, como o fato de não utilizar radiação ionizante, evitando riscos ao paciente (exceto em condições específicas, como no caso de pessoas que utilizam marca-passo). Outra vantagem do imageamento por RM é que esta técnica não necessita da injeção de contrastes para tecidos moles, que também pode ser prejudicial à alguns pacientes com quadros de alergia.

Apesar destas vantagens, existem algumas dificuldades relacionadas as imagens de pulmões obtidas por RM. Uma delas, conforme Mills et al. (2003) é sua baixa densidade de rotação de prótons, proporcionando sinal mais baixo de RM do que outros tecidos, tais como o parênquima cerebral. Além disso, os campos magnéticos estáticos dentro do tórax variam devido à diferença de susceptibilidade magnética entre o oxigênio paramagnético no ar e o tecido diamagnético. Este efeito é ainda agravado pela geometria complexa dos pulmões. Biederer (2009) também destaca a questão do movimento contínuo de todos os órgãos do tórax, induzidos pelo movimento do coração e dos próprios pulmões, que podem prejudicar a qualidade da imagem. Apesar destes problemas, o imageamento por RM ainda é o mais viável para a aplicação em questão, que exige um exame mais longo devido ao fato de serem necessárias sequências de imagens, sem expor o paciente à radiação ionizante.

Desta forma, este trabalho utilizou imagens de pulmões em movimento obtidas por meio de RM. O escopo deste trabalho foi realizar a segmentação destas sequências de imagens de forma automática, sem a necessidade de ajustes de parâmetros conforme a sequência, devido à grande quantidade de sequências e também porque estas variavam bastante em forma e contraste, de acordo com o paciente e também de acordo com a fatia dos pulmões. As Figuras 6 (a) e (c) trazem exemplos

de uma imagem coronal e uma imagem sagital, respectivamente, que possuem bom contraste. Já as Figuras 6 (b) e (d) são exemplos de uma imagem coronal e uma imagem sagital com baixo contraste. Neste tipo de imagem a segmentação é mais difícil, pois os pixels pertencentes aos pulmões e os pixels da caixa torácica possuem valores muito próximos, sendo muitas vezes não distinguidos pelos métodos de segmentação.

Figura 6: Exemplos de imagens com diferentes contrastes. (a) Imagem coronal com bom contraste. (b) Imagem coronal com baixo contraste. (c) Imagem sagital com bom contraste. (d) Imagem sagital com baixo contraste.




Fonte: Hospital Kanagawa (2004-2006).

Variações em relação à forma são apresentadas na Figura 7, onde é possível verificar a diferença de forma e tamanho percebidas em sequências de um mesmo paciente obtidas a partir de fatias diferentes. As Figuras 7 (a) e (c) apresentam fatias mais iniciais dos pulmões, para

uma imagem coronal e sagital, respectivamente. A Figura 7 (b) apresenta uma fatia coronal do final dos pulmões. Já a Figura 7 (d), apresenta uma fatia sagital do meio dos pulmões.

Figura 7: Exemplos de diferentes formas em pulmões de um mesmo paciente. (a) Imagem coronal do início dos pulmões. (b) Imagem coronal do final dos pulmões. (c) Imagem sagital do início dos pulmões. (d) Imagem sagital do meio dos pulmões.



Fonte: Hospital Kanagawa (2004-2006).

Neste trabalho foi desenvolvida uma solução de segmentação baseada em Modelos Ativos de Forma (ASM, do inglês *Active Shape Models*), que dentre diversos métodos testados na fase inicial desta pesquisa, como limiarização, operações morfológicas, crescimento de regiões, *watershed*, *snakes* e *level-sets* (apresentados no Apêndice A), apresentou os melhores resultados e foi o único que não necessitou de ajustes de parâmetros, independente da sequência segmentada. A solução apre-

sentada pode ser dividida em duas etapas principais: a geração do conjunto de treinamento utilizada pelo ASM e a identificação e segmentação dos pulmões.

Como as imagens disponíveis na base utilizada não possuem segmentações realizadas por um especialista, houve inicialmente a necessidade de segmentar as imagens a serem utilizadas no treinamento. Visto que devido ao tamanho da base, esta era uma tarefa cuja execução de forma manual seria exaustiva, consumindo um tempo considerável do trabalho, foi proposto um método semi-automático para realizar a segmentação do conjunto de treinamento. Neste método apenas uma imagem de cada sequência do treinamento precisa ser segmentada manualmente, sendo utilizada como referência para a segmentação das demais imagens da sequência. Além disso, como mencionado anteriormente, a forma dos pulmões pode apresentar bastante variação dependendo da fatia em que foi obtida, conforme a Figura 7. Desta forma percebeu-se a necessidade de dividir o treinamento em grupos diferentes, conforme a localização das fatias dos pulmões. A etapa de segmentação inicia com a identificação dos pulmões, utilizando Histogramas de Gradientes Orientados (HOG, do inglês *Histogram of Oriented Gradients*), para localizar os pulmões na imagem, com o objetivo de iniciar a segmentação a partir do local mais apropriado, fazendo com que o algoritmo de ASM utilize menos iterações. HOG também foi utilizado para, dada uma sequência a ser segmentada, classificá-la em um dos grupos de treinamento, utilizando o treinamento mais adequado para realizar sua segmentação. Nesta etapa, diversos testes foram conduzidos para identificar parâmetros que trouxessem bons resultados para todas as sequências testadas. Uma vez identificados, estes parâmetros foram fixados e utilizado para a segmentação da base de dados completa de forma totalmente automática.

O trabalho de segmentação apresentado tem a finalidade de gerar as silhuetas de entrada para um trabalho de reconstrução 4D dos pulmões, proposto por Abe (2013), desenvolvido na Universidade de São Paulo (Brasil), em parceria com a Universidade Nacional de Yokohama

(Japão) e o Hospital Kanagawa Cardiovascular and Respiratory Center (Japão). A base de imagens utilizada nesta pesquisa foi obtida segundo um protocolo aprovado pelo Comitê de Ética Médica do Hospital Kanagawa Cardiovascular and Respiratory Center. A Universidade do Estado de Santa Catarina foi autorizada a utilizar esta base, dando prosseguimento às pesquisas iniciais. A base contém imagens de 6 pacientes com idades entre 24 e 58 anos. Cada paciente contém aproximadamente 14 sequências sagitais e 14 sequências coronais, com 50 imagens por sequência, totalizando mais de 8000 imagens.

Esta dissertação segue com o Capítulo 2, que apresenta os fundamentos teóricos envolvidos neste trabalho. O Capítulo 3 apresenta trabalhos relacionados com esta dissertação. O Capítulo 4 apresenta a proposta de solução desenvolvida. O Capítulo 5 apresenta os testes realizados de modo a encontrar a melhor forma de aplicar ASM no problema da segmentação de sequências de pulmões obtidos por RM. Também são apresentados os resultados obtidos com a solução desenvolvida, bem como os problemas encontrados e uma avaliação dos resultados. O Capítulo 6 apresenta as conclusões sobre o trabalho realizado. O trabalho ainda contém o Apêndice A que mostra uma comparação de outros métodos, além do ASM, que foram testados na etapa inicial deste trabalho. O Apêndice B ainda apresenta exemplos de segmentações para 5 pacientes da base de dados utilizada.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo inicia com uma introdução sobre os diferentes métodos de aquisição de imagens médicas. Também são apresentadas as técnicas utilizadas no desenvolvimento do trabalho. Elas podem ser separadas em dois grupos: as técnicas utilizadas para a detecção dos pulmões e as técnicas utilizadas para a segmentação dos pulmões, detalhadas na sequência.

2.1 Aquisição de Imagens Médicas

Imagens médicas podem ser obtidas utilizando técnicas diferentes, dependendo da finalidade da imagem. As técnicas mais comumente utilizadas são:

- a) Raios-X: os raios-X para formação de imagens são gerados em um tubo a vácuo com um cátodo e um ânodo. O cátodo é aquecido, fazendo com que elétrons sejam liberados. Esses elétrons se movimentam em alta velocidade na direção do ânodo positivamente carregado. Quando os elétrons atingem um núcleo, a energia é liberada na formação de radiação de raios-X. A energia, ou capacidade de penetração dos raios-X, é controlada por uma tensão através do anodo e por uma corrente no filamento do cátodo (GONZALEZ; WOODS, 2010).

Os raios-X têm a capacidade de atravessar materiais de baixa densidade, como por exemplo, os músculos do corpo humano, porém são absorvidos por materiais de maior densidade, como os ossos. De acordo com a densidade da estrutura, haverá maior ou menor absorção dos raios. A radiação resultante após a interação dos raios-X com o paciente, irá sensibilizar um filme radiográfico, semelhante ao filme fotográfico. Este filme é composto de sais de prata (AgBr, AgI). Quando sen-

sibilizado por um fóton de raio-X ou pela luz visível, o cátion de prata (íon positivo) acaba sendo neutralizado e vira óxido metálico (AgO), e escurece. Por outro lado, o sal de prata que não foi sensibilizado pelo raio-X ou pela luz permanece transparente (LEITE; AMARO; OTADUY, 2015).

- b) Tomografia Computadorizada (TC): conforme Garib et al. (2007), o aparelho de TC tradicional apresenta três componentes principais: o *gantry*, no interior do qual se localizam o tubo de raios-X e um anel de detectores de radiação, constituído por cristais de cintilação, a mesa que acomoda o paciente e o computador, que reconstrói a imagem tomográfica a partir das informações adquiridas no *gantry*. A fonte de raios-X emite um feixe estreito em formato de leque, através de uma seção transversal do paciente. Durante o exame, o tubo de raios-X gira dentro do anel de receptores. Ao atravessar o paciente, os raios são coletados pelos receptores, sendo que os sinais recebidos variam de acordo com o grau de absorção do tecido atravessado pelo feixe. Os sinais recebidos são convertendo-os em pulsos elétricos que são digitalizados por um sistema computacional, gerando a imagem.

Conforme Mills et al. (2003), esta técnica requer um imageamento rápido devido a exposição potencialmente alta do paciente à radiação ionizante, que pode ser prejudicial à saúde. Os átomos do corpo humano estão unidos, formando moléculas, como por exemplo, a molécula da água e a molécula do DNA (*Deoxyribonucleic Acid*, ou Ácido Desoxirribonucleico). Esses átomos estão unidos por forças elétricas. Quando uma partícula ionizante arranca um elétron de um dos átomos de uma molécula, pode causar sua desestabilização que resulta em quebra da molécula. Segundo Okuno (2013), existem dois mecanismos de ação possíveis: direto (quando a radiação interage diretamente com as moléculas de DNA, podendo causar desde mutação genética até morte celular) e indireto

(quando a radiação quebra a molécula da água, formando assim radicais livres que podem atacar outras moléculas importantes).

- c) Tomografia de Impedância Elétrica (TIE): conforme Costa, Lima e Amato (2009) a TIE é um método para aquisição de imagens em tempo real, não invasivo e livre de radiação, que vem sendo cada vez mais utilizado no monitoramento pulmonar. A TIE utiliza a injeção de correntes elétricas de alta frequência e baixa amplitude ao redor do tórax, para obter imagens de sessões transversais dos pulmões. Estas correntes são aplicadas através de eletrodos e atravessam o tórax de acordo com as impedâncias de suas estruturas internas. Os potenciais elétricos resultantes entre dois eletrodos são medidos e usados para obter a distribuição de impedância elétrica dentro do tórax através de um algoritmo de reconstrução.
- d) Ultrassom: as ondas ultrassom são ondas mecânicas com frequência acima da faixa de audição humana (20KHz). A velocidade com que estas ondas se propagam depende diretamente do meio de propagação. Desta forma, este método de aquisição de imagens utiliza transdutores, caracterizados por conterem cristais piezelétricos em seus interiores. Estes cristais tem a capacidade de converter sinais elétricos oscilantes em ondas acústicas, e vice-versa. As ondas de ultrassom são transmitidas pelo transdutor em um fluxo contínuo. Assim, a imagem por ultrassom é o resultado dos ecos destas ondas, que ao entrarem em contato com a superfície entre dois meios de impedâncias acústicas (resistência do tecido ao movimento das partículas causado pelo ultrassom) distintas, é refletida e retorna ao transdutor (MASSELLI; WU; PINHEDO, 2013).
- e) Ressonância Magnética (RM): uma das propriedades funda-

mentais das partículas subatômicas é conhecida como spin, que compreende na rápida movimentação dos elétrons ao redor do núcleo atômico, gerando campos eletromagnéticos. Isto faz com que eles se comportem como pequenos ímãs, ou dipolos magnéticos. Dentro de núcleos com número par de partículas, os campos magnéticos desses dipolos são mutuamente anulados, gerando momentos magnéticos resultantes nulos. Porém, em núcleos com número ímpar de partículas o momento magnético nuclear resultante não é anulado, uma vez que sempre há uma partícula cujo campo magnético não foi neutralizado. Este tipo de núcleo é suscetível à influencia de campos magnéticos externos, sendo chamado de núcleo ativo (ALEGRO, 2009, p. 23). Um exemplo de elemento de núcleo ativo é o hidrogênio, que está presente em grande proporção no corpo humano.

O aparelho onde o exame de RM é realizado possui o formato de um tubo circundado por um grande ímã, que produz um potente campo magnético. Quando este campo magnético é aplicado, os átomos se alinham a ele. Moléculas em baixo estado de energia irão absorver a energia da onda eletromagnética (fóton) e pular para um nível mais alto de energia. A tendência natural é que estas moléculas voltem ao estado de energia inicial, emitindo a radiação eletromagnética absorvida. É por meio da medição e análise desta radiação emitida que são obtidas as imagens de RM.

2.2 Detecção dos pulmões

O passo inicial do processo de segmentação feito neste trabalho consiste em identificar a localização dos pulmões para então iniciar a segmentação a partir do local mais adequado. Assim inicialmente é feita sua detecção utilizando o descritor HOG, explicado neste seção.

2.2.1 Histograma de Gradientes Orientados

Segundo Duda, Hart e Stork (2001), o objetivo principal de um descritor de características é caracterizar um objeto de acordo com medidas cujos valores sejam muito similares para objetos da mesma categoria e muito diferentes para objetos de categorias diferentes. Isto implica em buscar por características que sejam invariantes para transformações afins, como translação, rotação ou escala. Assim como na segmentação, a escolha de um descritor depende do domínio do problema a ser resolvido.

Neste trabalho foi utilizado o descritor HOG, uma vez que para a implementação deste trabalho foi utilizada uma biblioteca na qual o algoritmo para o mesmo estava disponível, apresentando bons resultados para esta aplicação.


Conforme Dalal e Triggs (2005), a ideia principal do descritor HOG, é que a aparência e forma de um objeto podem ser caracterizados pela distribuição de gradientes de intensidade locais ou pelas direções das bordas.

Na prática, inicialmente, a partir de um conjunto de imagens de treinamento, são coletadas amostras positivas do objeto (por exemplo, pulmões) e amostras negativas (outras partes da imagem, como outros órgãos ou fundo da imagem). Todas estas amostras são reescaladas para o mesmo tamanho, que normalmente corresponde ao tamanho da menor amostra. Cada amostra é dividida em pequenos grupos de pixels, denominados células. Em cada célula é calculado um histograma local de direções de gradiente, como mostra a Figura 8.

O resultado do descritor é a lista destes histogramas. Conforme Dalal e Triggs (2005), para uma melhor invariância a iluminação, sombreamento, entre outros, as células são ainda agrupadas em blocos, sendo feita então uma normalização. No exemplo da Figura 9 (b), a amostra da Figura 9 (a) foi dividida em células de 16x16 pixels.


Os vetores de características das amostras são utilizados para

Figura 8: Exemplo de célula e seu respectivo histograma.



Fonte: Produção da autora, 2016.

Figura 9: Representação dos histogramas de gradientes orientados de uma imagem. (a) Imagem de entrada. (b) Representação dos histogramas de gradiente da imagem de entrada.



Fonte: Produção da autora, 2016.

treinar uma Máquina de Vetores de Suporte (SVM, do inglês, *Support Vector Machine*), um classificador binário que é descrito na próxima sessão. O tamanho das amostras irá definir o tamanho da janela de busca: a imagem de entrada é percorrida, deslizando a janela de busca por toda a imagem. O vetor de características de cada janela é computado, assim a SVM irá identificar se a janela representa o objeto ou outras partes indesejadas da imagem.

Normalmente o objeto de interesse pode aparecer múltiplas vezes em uma mesma imagem e em variados tamanhos, como por exemplo, quando se deseja detectar pessoas em uma multidão. Neste caso, a imagem de entrada é percorrida em múltiplas escalas, sempre utilizando o mesmo tamanho de janela de busca. Assim, um objeto que não foi detectado na primeira vez, por ter um tamanho maior do que a janela de busca, será detectado nos passos subsequentes.


2.2.2 Máquinas de Vetores de Suporte

As SVMs foram propostas em 1979, por Vladimir Vapnik. Sua ideia principal, conforme Cortes e Vapnik (1995) é classificar elementos de duas classes utilizando uma margem de decisão com propriedades especiais que garantem uma classificação com alta capacidade de generalização para ambas as classes.

Isto é obtido com a maximização da margem, situação em que a distância entre a margem e o elemento mais próximo da primeira classe é igual a distância entre a margem e o elemento mais próximo da segunda classe, o que caracteriza um hiperplano ótimo, como mostrado na Figura 10, onde tem-se um hiperplano ótimo separando elementos da classe dos círculos brancos e da classe dos círculos pretos. Caso o hiperplano estivesse muito próximo dos círculos pretos, se uma nova amostra desta classe fosse adicionada, as chances de ficar do lado errado da margem seriam grandes, assim como se o hiperplano estivesse muito próximo dos círculos brancos e uma nova amostra desta classe fosse adicionada, teria grandes chances de ficar do lado da margem que abrange

a classe dos círculos pretos. Este hiperplano ótimo pode ser definido pelos vetores (neste casos, representados pelos círculos) que cruzam as retas de suporte (pontilhadas).

Figura 10: Hiperplano ótimo.




Fonte: Produção da autora, 2016.

Os exemplos apresentados tratam de duas classes linearmente separáveis, o que dificilmente acontece em casos reais. A Figura 11 (a) apresenta um caso de elementos que não são linearmente separáveis. Isto pode ser solucionado projetando os dados em um plano de maior dimensão, chamado espaço de características, onde podem ser separados linearmente, conforme a Figura 11 (b). Esta projeção para um plano de maior dimensão é feita a partir de uma função de *kernel*.

Assim, conforme Cortes e Vapnik (1995), a função de decisão para SVM é dada pela Equação 2.1, onde N é o número de vetores de suporte, α_i e b são os parâmetros definidos no treinamento, x é vetor de características e K é a função de *kernel*.

$$f(x) = \sum_{i=1}^N \alpha_i K(x, x_i) + b \quad (2.1)$$

Figura 11: Projeção de dados para plano de maior dimensão. (a) Dados linearmente inseparáveis. (b) Dados projetados em plano de maior dimensão, linearmente separáveis.



Fonte: Produção da autora, 2016.

2.2.2.1 Support Vector Machine multiclass

SVM são classificadores binários, ou seja, elas separam duas classes. Entretanto, a maioria dos problemas reais possui mais do que somente duas classes. Neste trabalho, por exemplo, como o treinamento foi dividido em grupos diferentes conforme o tipo de fatia, a partir de uma sequência de imagens de entrada existe a necessidade de identificar qual dos grupos do treinamento é mais adequado para sua segmentação. Assim, em casos onde existem mais de duas classes, são empregadas abordagens para que este tipo de classificador possa ser aplicado. Conforme Ma e Guo (2014) existem duas abordagens clássicas:

- a) um-contra-todos: são construídos k classificadores binários separados. O m -ésimo classificador é treinado usando as amostras da m -ésima classe como exemplos positivos e as amostras das outras $k - 1$ classes como exemplos negativos. Durante o teste, a classe de uma amostra é definida pelo classificador binário que resultou no maior valor de saída.
- b) um-contra-um: consideram-se todos os pares possíveis de classificadores, ou seja $k(k - 1) / 2$ classificadores binários

são construídos. Durante os testes, cada classificador contribui com um voto e a amostra é rotulada com a classe que recebeu mais votos.

2.3 Segmentação de imagens

A segmentação subdivide uma imagem em regiões ou objetos que a compõe. O nível de detalhamento em que a subdivisão é realizada depende do problema a ser resolvido. Ou seja, a segmentação deve parar quando os objetos ou regiões de interesse de uma aplicação forem detectados. Por exemplo, na inspeção automatizada de componentes eletrônicos, o interesse está em analisar as imagens dos produtos com o intuito de determinar a presença ou ausência de anomalias específicas como a falta de componentes ou circuitos de conexão interrompidos (GONZALEZ; WOODS, 2010, p. 454).

Diferentes técnicas podem ser utilizadas no processo de segmentação. Na fase inicial deste trabalho foram testadas técnicas tradicionais na segmentação de órgãos: limiarização, operações morfológicas, crescimento de regiões, *watershed*, *snakes*, *level-sets* e ASM. O Apêndice A apresenta os resultados destes testes. Dentre os métodos testados, o ASM se mostrou mais eficiente, levando a segmentações melhores de forma automática. Também foi verificado que com algumas melhorias o método de crescimento de regiões poderia ser empregado para segmentar de forma semi-automática as imagens para treinamento do ASM, que são muitas. Assim, em sequência são apresentadas estas e outras técnicas de segmentação auxiliares utilizadas neste trabalho.

2.3.1 Morfologia matemática

Segundo Dougherty e Lotufo (2003), o escopo da morfologia matemática é tão amplo quanto o próprio conceito de processamento de imagens, incluindo ajustes de imagens, segmentação, restauração, detecção de bordas, análise de textura, entre outros. Ela é aplicada com


sucesso em diversas áreas, como na visão de robôs, sensoriamento remoto, metalurgia, documentos digitais e biologia. Dentre as operações morfológicas mais básicas, pode-se destacar a dilatação e erosão como operações primárias na morfologia matemática, seguidas de operações secundárias como as de abertura e fechamento.

a) *dilatação e erosão*: a dilatação é a convolução de uma imagem A , com um núcleo (elemento estruturante) B . O núcleo pode ter qualquer forma ou tamanho, com um ponto de ancoragem em seu centro. O núcleo pode ser considerado como uma máscara, e seu efeito de dilatação é o de um operador local máximo. Quando o núcleo B é digitalizado sobre a imagem, calcula-se o valor de pixel máximo comum a B e substitui-se o pixel da imagem sob o ponto de ancoragem com esse valor máximo. Isto faz com que as regiões brilhantes dentro de uma imagem cresçam. Este crescimento é a origem do termo "operador de dilatação". A erosão é a operação inversa. A ação do operador erosão é equivalente a calcular um mínimo local sobre a área do núcleo. Quando o núcleo B é digitalizado sobre a imagem, calcula-se o valor de pixel mínimo comum a B e substitui-se o pixel da imagem sob o ponto de ancoragem com esse valor mínimo. Em geral, ao passo que a dilatação expande região A , a erosão reduz região A (BRADSKI; KAEHLER, 2008). A Figura 12 (a) apresenta uma imagem original, seguida dos resultados de sua dilatação na Figura 12 (b) e erosão na Figura 12 (c), com elementos estruturantes no formato de um disco de raio 3.

b) *abertura e fechamento*: a erosão, além de diminuir algumas regiões, pode suavizar pequenas estruturas, porém estas podem ser recuperadas após a aplicação de uma dilatação. Esta sequência de operações, uma erosão seguida de dilatação, é chamada de abertura morfológica. Esta operação remove completamente regiões que não contêm o elemento

estruturante, suavizando contornos, quebrando conexões estreitas e removendo saliências. Já o fechamento morfológico consiste de uma dilatação seguida de uma erosão. Além de suavizar contornos, a operação de fechamento funde pequenas quebras e alarga golfos estreitos eliminando pequenos orifícios menores que o elemento estruturante (GONZALEZ; WOODS, 2010). A Figura 13 apresenta uma imagem original na Figura 13 (a), seguida dos resultados de sua abertura na Figura 13 (b) e fechamento na Figura 13 (c), ambas utilizando um elemento estruturante no formato de um disco de raio = 3.


Figura 12: Dilatação e erosão. (a) Imagem original. (b) Imagem dilatada. (c) Imagem erodida.



Fonte: Produção da autora, 2016.

Neste trabalho a operação de dilatação foi utilizada para aumentar o tamanho de silhuetas segmentadas manualmente a partir de uma única imagem de cada sequência do treinamento, com o objetivo de gerar marcadores, utilizados pelo método Crescimento de Regiões como referência para segmentar as demais imagens de suas respectivas sequências. O método Crescimento de Regiões é abordado em sequência.

Figura 13: Abertura e fechamento. (a) Imagem original. (b) Imagem após abertura. (c) Imagem após fechamento.



Fonte: Produção da autora, 2016.


2.3.2 Crescimento de regiões

Algoritmos para crescimento de regiões são baseados na agregação progressiva de pixels a partir de um ponto ou conjunto de pontos iniciais denominado “semente”, de acordo com um critério. Como critério de agregação, pode-se considerar, por exemplo, todos os pixels cujo valor for inferior ao valor da média dos pixels que já pertencem a região. Os pixels vizinhos da semente são examinados sucessivamente; se eles atenderem ao critério de agregação, são incluídos na região, se não, são rejeitados. Um exemplo é comparar o valor do pixel a ser testado com a média dos pixels que já se encontram na região.

Em relação a vizinhança entre pixels, pode ser considerada uma vizinhança-4 ou uma vizinhança-8. Segundo Gonzalez e Woods (2010), dado um pixel p de coordenada (x, y) , sua vizinhança-4 é formada pelos 4 pixels com distância unitária em relação a p , que podem estar nas direções vertical e horizontal: $(x + 1, y)$, $(x - 1, y)$, $(x, y + 1)$, $(x, y - 1)$, ou nas diagonais: $(x + 1, y + 1)$, $(x + 1, y - 1)$, $(x - 1, y + 1)$, $(x - 1, y - 1)$. Exemplos são apresentados nas Figuras 14 (a) e (b), respectivamente. A união destes dois grupos de pixels forma uma vizinhança-8, como mostra

a Figura 14 (c).

Figura 14: Tipos de vizinhança. (a) Vizinhança-4 (vertical e horizontal). (b) Vizinhança-4 (diagonal). (c) Vizinhança-8.




Fonte: Fonte: Produção da autora, 2016.

A Figura 15 mostra um exemplo de segmentação utilizando crescimento de regiões, cujo critério de agregação selecionava apenas pixels com valor maior ou igual que um limiar T . Foi utilizada uma semente fixa no centro da imagem. Neste caso foi considerada uma vizinhança-4.

Segundo Rogowska (2009), o resultado do crescimento de regiões depende fortemente da seleção do critério de homogeneidade. Se este não for devidamente escolhido, as regiões podem “vazar” para áreas adjacentes ou misturar-se com regiões que não pertencem ao objeto de interesse. Outro problema é que diferentes sementes podem levar a regiões não idênticas. Por outro lado, uma vantagem do crescimento de regiões é que a técnica é capaz de segmentar corretamente regiões que tem as mesmas propriedades e estão espacialmente separadas. Outra vantagem é que ela gera regiões conectadas.

Uma forma de evitar o problema de vazamento é a utilização de informações de forma na segmentação por crescimento de regiões. Em Rose et al. (2007) uma forma de referência é previamente definida e registrada sobre a imagem a ser segmentada. Calcula-se a distância entre um pixel da imagem a ser segmentada e o pixel mais próximo do contorno de referência. Distâncias negativas indicam que o pixel esta dentro

Figura 15: Crescimento de regiões. (a) Imagem original. (b) Semente fixada no centro da imagem. (c) - (g) Passos intermediários do processo de segmentação. (f) Pulmão segmentado.



Fonte: Produção da autora, 2016.

do contorno de referência, auxiliando sua agregação à região. Distâncias positivas indicam que o pixel está fora do contorno de referência, contrariando o critério de agregação. Quando a distância se aproxima de 0, o pixel está próximo ao contorno de referência, então o critério de agregação se torna mais seletivo.

Neste trabalho o Crescimento de Regiões com forma de referência é utilizado na segmentação das imagens para treinamento do método ASM, descrito em sequência, uma vez que a segmentação manual de todo o conjunto de treinamento é uma tarefa de difícil execução, devido à grande quantidade de imagens.

2.3.3 Modelos Ativos de Formas

Seguindo a ideia de Modelos de Contornos Ativos, onde um modelo flexível é atraído pelas características da imagem, Cootes et al. (1995) introduz o conceito de Modelos Ativos de Formas, comumente referidos como ASM. Um conceito fundamental para ASM é a Análise de Componentes Principais (PCA, do inglês *Principal Component Analysis*). Assim, esta sessão incia com uma introdução sobre o conceito de PCA, seguida do funcionamento do ASM.

2.3.3.1 *Principal Component Analysis*

Conforme Jolliffe (2002), a ideia principal da PCA é reduzir a dimensionalidade de um conjunto de dados em que há um grande número de variáveis interrelacionadas, mantendo o máximo possível da variação presente no conjunto, facilitando também sua visualização. Esta redução é feita através da obtenção de um novo conjunto de variáveis, as Componentes Principais (PCs), que são não correlacionadas, sendo ordenadas de modo a que a primeira PC retém a maior parte da variação das variáveis originais, a segunda PC define a próxima maior e assim por diante. De forma geral, a primeiras PC são as responsáveis pela maior variabilidade do conjunto, já as últimas tem contribuição insignificante.

O cálculo das PCs, para conjuntos de dados com n dimensões, é feito da seguinte maneira:

- a) Define-se o conjunto de dados,

$$x_1, \dots, x_s \quad (2.2)$$

vetores em um conjunto de amostras n -dimensionais.

- b) Calcula-se o vetor médio dos dados (\bar{x}), pela Eq. 2.3, onde s é o número de vetores e x_i percorre os s vetores do conjunto de dados.

$$\bar{x} = \frac{1}{s} \sum_{i=1}^s x_i \quad (2.3)$$

c) Calcula-se a matriz de covariância dos dados, pela Eq. 2.4:

$$s = \frac{1}{s-1} \sum_{i=1}^s (x_i - \bar{x})(x_i - \bar{x})^T \quad (2.4)$$

d) São encontrados os autovalores e autovetores para a matriz de covariância. A partir deles é montada uma matriz ϕ , cujas linhas correspondem aos autovetores da matriz de covariância, organizados em ordem crescente conforme seus autovalores. Por exemplo, a primeira linha da matriz deve ser o autovetor com maior autovalor associado e irá corresponder a primeira PC do conjunto de dados, e assim sucessivamente, como mostra a Equação 2.5, onde p são os autovetores:

$$\phi = (p_1|p_2|\dots|p_t)^T \quad (2.5)$$

e) A matriz obtida é utilizada para análise dos dados, conforme o problema de aplicação.

2.3.3.2 Modelos Ativos de Forma

Conforme Cootes (2000), um objeto pode ser descrito por um conjunto de n pontos, que formam seu contorno. Os conjuntos de pontos são definidos manualmente para um conjunto de s imagens. Cada imagem é representada por uma matriz formada pelo conjunto de pontos mais representativos de seu contorno, como apresenta a Equação 2.6, sendo cada ponto representado por sua coordenada x e y :

$$\mathbf{x} = (x_1 \ y_1, x_2 \ y_2, \dots, x_n \ y_n)^T \quad (2.6)$$

Bookstein (1991) chama estes pontos de *landmark points* e os classifica conforme sua utilidade. De acordo com Cootes et al. (1995), para ASM, essa classificação pode ser reduzida, considerando-se 3 tipos principais de pontos:

1. Pontos com significância particular dependendo da aplicação, tais como o centro de um olho em um modelo de face ou cantos acen- tuados em um contorno (Pontos de tipo 1);
2. Pontos marcando detalhes independentes da aplicação, como o maior ponto em determinada orientação ou curvatura extrema (Pon- tos de tipo 2);
3. Outros pontos que podem ser interpolados a partir dos pontos de tipo 1 e 2, por exemplo, pontos igualmente espaçados entre dois pontos de tipo 1 (Pontos de tipo 3).

Conforme Cootes et al. (1995), os pontos de Tipo 1 são preferí- veis aos pontos de tipo 2, uma vez que são de identificação mais fácil e precisa.

Após a definição dos conjuntos de pontos de cada imagem, se- guindo os conceitos de PCA, a Equação 2.3 é utilizada para calcular uma forma média entre as s imagens do conjunto de treinamento, representa- das na forma da Equação 2.6. Antes da obtenção da forma média, pode ser necessário que as formas passem por uma etapa de alinhamento (translação, rotação e escala), visto que o objeto pode se encontrar em diferentes posições e em diferentes tamanhos conforme a imagem. A ma- triz de covariância é calculada (Equação 2.4) juntamente com seus auto- valores e autovetores, montando uma matriz Φ , a partir dos t autoveto- res, correspondentes aos t maiores autovalores da matriz de covariância, sendo t o número de autovalores necessários para atender a condição da Equação 2.7. A variável fv define a proporção da variância total desejada, por exemplo, 0,98 para 98% e λ_i representa um autovalor.

$$\sum_{i=1}^t \lambda_i \geq fv \sum \lambda_i \quad (2.7)$$

Ao final da segmentação, esta matriz Φ será utilizada para apro- ximar uma forma segmentada através da Equação 2.8.


$$x = \bar{x} + \Phi b \quad (2.8)$$

onde b é definido como:

$$b = \Phi^T (x - \bar{x}) \quad (2.9)$$


Os autovetores na matriz ϕ definem um novo sistema de coordenadas para o conjunto de amostras, centrados em sua média, como mostra a Figura 16, que representa um conjunto de amostras em 2 dimensões. O parâmetro b representa as coordenadas mais significativas das formas neste novo sistema, sendo que um ponto x qualquer pode ser aproximado pelo ponto mais próximo no eixo principal p (correspondente ao primeiro autovetor, ou primeira PC).

Figura 16: Aplicação de PCA em conjunto de amostras em 2 dimensões. p : eixo principal. x pode ser aproximado pelo ponto mais próximo no eixo p : $x \approx x' = \bar{x} + bp$.



Fonte: Cootes (2000).

A segmentação em si, acontece da seguinte maneira: é obtido um perfil de níveis de cinza para cada ponto da forma média, que deverá ser procurado na imagem a ser segmentada. Dada uma imagem do treinamento, é traçada uma reta perpendicular para cada ponto (p_i), gerada através da rotação em 90° do vetor que vai de p_{i-1} à p_{i+1} , como na Figura 17.

Figura 17: Reta normal ao ponto p_i .

Fonte: Produção da autora, 2016.


Esta reta possui tamanho de $2k + 1$, onde k é o parâmetro que irá definir o tamanho do perfil de níveis de cinza, que é formado por k pixels de cada lado do ponto juntamente com o pixel referente ao próprio ponto. Os níveis de cinza dos pixels correspondentes a reta de cada ponto são armazenados em vetores, chamados de perfis de níveis de cinza. Este processo é feito para todas as imagens do conjunto de treinamento, sendo possível perceber um padrão nos perfis de níveis de cinza destas imagens. No caso de pulmões, por exemplo, estes perfis são representados por uma transição entre pixels escuros (interior do pulmão) e pixels mais claros (caixa torácica), como exemplifica a Figura 18.

Utilizando as s imagens do treinamento, são obtidos perfis médios de níveis de cinza para cada ponto da forma média, sendo eles normalizados, formando perfis estatísticos de níveis de cinza, como mostra a Equação 2.10, onde $\sum_j |g_{ij}|$ representa a soma do módulo de cada um dos elementos do perfil g_i ($g_{i1}, g_{i2}, \dots, g_{ij}$).

$$g_i \rightarrow \frac{1}{\sum_j |g_{ij}|} g_i \quad (2.10)$$

A forma média \bar{x} é posicionada sobre a imagem a ser segmen-

Figura 18: Exemplo de pulmão do conjunto de treinamento com os respectivos perfis de tons de cinza de cada ponto, representados por uma transição abruptada de níveis de cinza.




Fonte: Produção da autora, 2016.

tada e para cada um dos pontos de seu contorno são obtidas retas normais de tamanho $2m + 1$, sendo $m > k$, como mostra a Figura 19, onde a linha tracejada vermelha indica a forma média obtida pelo treinamento e as linhas azuis representam as retas de tamanho $2m + 1$ para cada ponto da forma média.

Vetores com os níveis de cinza destas retas são montados, tal como anteriormente, sendo chamados de perfis normais e referidos como g_s . Os pontos da forma média são então movimentados ao longo destes perfis normais, de modo a encontrar a borda desejada. uma vez que os perfis normais são formados por $2m + 1$ pixels, a partir deles é possível gerar $2(m - k) + 1$ subvetores de tamanho $2k + 1$, como mostra a Figura 20. A imagem superior representa um perfil de tons de cinza (g_i) formado a partir de um k de tamanho 2, e a imagem inferior representa um perfil normal (g_s) formado a partir de um m de tamanho 7. Em sequên-

Figura 19: Retas com tamanho $2m + 1$ (azul) são traçadas para cada ponto da forma média (vermelho).



Fonte: Produção da autora, 2016.


cia são mostrados todos os subvetores que podem ser formados a partir de g_s .

É realizada uma busca, comparando g_i com cada um dos subvetores, verificando qual subvetor gera a menor distância $f(g_s)$, calculada utilizando a distância de Mahalanobis, conforme Equação 2.11, onde S_g é a matriz de covariância de g_i .

$$f(g_s) = \sqrt{(g_s - g_i)^T S_g^{-1} (g_s - g_i)} \quad (2.11)$$

Cada ponto da forma média \bar{x} é movido para o ponto central do subvetor que minimiza $f(g_s)$, como mostra a Figura 21, onde as linhas azuis indicam os perfis normais e as linhas verdes indicam os subvetores que minimizaram $f(g_s)$, ou seja, que mais se assemelhavam ao perfil g_i . Consequentemente, é possível verificar que o parâmetro m irá definir a porção da imagem onde será realizada a busca pelo perfil de níveis de cinza g_i . Este processo de reajuste de pontos é repetido por um número

Figura 20: Combinações possíveis de subvetores.




Fonte: Adaptado Cootes (2000, p. 14)

fixo de iterações, definido pelo usuário, ou até a convergência (por exemplo, quando 90% dos pontos não sofrerem mais alteração).

Após todos os pontos terem sido movidos para a melhor posição, a equação para aproximação de forma (Equação 2.8) é aplicada para ajustar a forma obtida.


Visto que a matriz ϕ é formada pelas formas do conjunto de treinamento, que nada mais é do que um conjunto de exemplos de contornos do objeto de interesse, esta matriz comprime as diferentes características que este objeto pode conter. Logo, ao aplicar esta matriz sobre um contorno segmentado, ela o aproxima da forma do objeto de interesse, mesmo que algum ponto do contorno tenha ficado em uma posição distante da posição mais correta, como por exemplo, em caso de este ponto ter ficado preso em algum mínimo local. A Figura 22 mostra um exemplo de um dos pulmões segmentado pelo método ASM antes (a) e depois da aplicação de PCA (b), que suavizou a forma e a tornou mais próxima da forma de um pulmão mesmo com vários pontos desalinhados.

Figura 21: Pontos da forma média movidos ao longo dos perfis normais (em azul), de acordo com o subvetor que minimiza a distância de Mahalanobis (em verde).



Fonte: Produção da autora, 2016.

Figura 22: Aplicação de PCA. (a) Forma segmentada antes da aplicação de PCA. (b) Forma segmentada após aplicação de PCA.



Fonte: Produção da autora, 2016.


O local de inicialização da forma média, pode ser definido de diferentes maneiras. Na detecção de faces feita por Cootes (2000), o posicionamento da face média é feito no centro da imagem e nas primeiras iterações do algoritmo é utilizado um valor maior para o parâmetro m , para fazer um ajuste grosso de posição e escala. São então utilizados valores menores para m nas próximas iterações, para ajustes mais finos. Já em Thai e Truong (2012), que também utiliza ASM no alinhamento de faces, é usado o algoritmo de detecção de faces de Viola e Jones (2004) para identificar a localização da face na imagem. Operações de escala, rotação e translação são aplicadas à face média para alinhá-la com a face da imagem analisada, sendo necessários apenas ajustes mais finos.

Cootes (2000) indica que uma forma de melhorar a eficiência e robustez do algoritmo é a sua implementação em multiresolução. Ou seja, primeiramente é feita uma busca do objeto em uma imagem de resolução mais baixa. A forma encontrada é usada para segmentar a próxima imagem, em uma resolução melhor e assim por diante. Isto evita que o algoritmo fique preso em estruturas erradas e também o torna mais rápido.

Este esquema é representado por uma pirâmide de imagem gaussiana, como mostra a Figura 23. Uma pirâmide é construída tanto para imagens de teste quanto para imagens de treino, onde o Nível 0 é representado pela imagem original e os níveis subsequentes são representados pela imagem anterior suavizada e com seu tamanho reduzido pela metade. Usualmente é utilizado o mesmo valor de k independente do nível da pirâmide. Em níveis mais elevados, o perfil normal irá abranger uma parte maior da imagem, levando o algoritmo a fazer movimentos mais largos nos níveis iniciais. Assim, em níveis mais baixos, ou seja, nas imagens de melhor resolução, são feitos movimentos menores e ajustes mais finos.

Uma vantagem apresentada por ASM, segundo Cootes (2000), é sua capacidade de rastrear objetos em sequências de imagens. ASM podem ser aplicados integralmente na primeira imagem de uma sequência para localizar o objeto em sua posição inicial. Assumindo que este

Figura 23: Pirâmide de imagem gaussiana.



Fonte: Adaptado de Cootes (2000, p. 15)

apresente pouca variação entre uma imagem e outra, a forma da imagem anterior pode ser utilizada como ponto de partida para a segmentar a próxima imagem, reduzindo assim o número de iterações necessárias à convergência do algoritmo.

O método ASM foi selecionado para realizar este trabalho de segmentação, visto que dentre os métodos testados, apresentados no Apêndice A, foi o que mostrou maior capacidade de automatização, pois os únicos ajustes de parâmetros aconteceram na etapa de testes do algoritmo. Foram testados diversos valores para os parâmetros k , m e f_v , que podem ser vistos no Capítulo 5. Foram identificados os valores que geravam resultados melhores para a maioria das sequências testadas e então estes parâmetros foram fixados, sendo utilizados para segmentar todas as sequências da base de imagens.

3 TRABALHOS RELACIONADOS

Foram encontrados poucos trabalhos focados na segmentação de sequências de imagens sagitais e coronais de pulmões obtidas por RM. A maioria dos trabalhos foca apenas na segmentação de imagens coronais ou axiais que contém apenas uma imagem por fatia. Na sequência são apresentados trabalhos que realizam a segmentação de pulmões utilizando técnicas variadas e diferentes tipos de imagens. Inicialmente são apresentados trabalhos que focam na segmentação de uma determinada fatia dos pulmões, contando com uma única imagem.

Tratando-se de imagens de TC, são apresentados os trabalhos de Leventon, Grimson e Faugeras (2000), Wang e Smedby (2014) e Okada et al. (2011).

Leventon, Grimson e Faugeras (2000) utilizam *Level-Set* juntamente com um modelo de forma estatístico (obtido por meio de um conjunto de treinamento), indicando possíveis limites para o objeto a ser segmentado. O posicionamento do modelo estatístico de forma na imagem a ser segmentada é feito sobre uma zona de confiança que indica a possível localização da estrutura de interesse. Esta zona de confiança é criada por meio de limiarização, sendo que o limiar T é definido conforme o órgão em questão, através da escala de Hounsfield (HU) (TAIRA; IGLESIAS; JAHANSHAD, 2010). Esta escala é usada na TC para medir os coeficientes de atenuação referentes a cada tecido do corpo humano. Nos pulmões, por exemplo, o ar aparece com aproximadamente -1000 HU. A região dos pulmões será na gama de -1000 a -400 HU. Já a parede torácica, sangue e ossos são muito densos e bem acima de -400 HU (SHOJAII; ALIREZAIE; BABYN, 2005).

Wang e Smedby (2014) utilizam a abordagem de Leventon, Grimson e Faugeras (2000) para realizar a segmentação de diversos órgãos, incluindo os pulmões no plano coronal. É utilizada uma abordagem *top*

down, onde as maiores estruturas são segmentadas primeiro e então suas informações de localização são passadas para as estruturas de nível mais baixo, em vez da utilização de uma zona de confiança obtida por limiarização. Foi realizada inicialmente a segmentação da cavidade ventral, seguida da segmentação dos pulmões, coração e cavidade abdominopélvica, que ficam contidos dentro da cavidade ventral. Em seguida foram segmentados os órgãos contidos dentro da cavidade abdominopélvica: bexiga, baço, fígado e rins.

O trabalho de Okada et al. (2011) realiza a segmentação de órgãos abdominais (fígado, baço, rins, pâncreas, vesícula biliar, da aorta e veia cava inferior). Em uma primeira etapa, a região abdominal é selecionada na imagem, sendo utilizada como referência o topo da cúpula do fígado. Esta região é extraída automaticamente aplicando ASM nos pulmões e então extraindo sua superfície inferior, que coincide com a região procurada. As imagens utilizadas foram obtidas a partir de 2 aparelhos diferentes e com diferentes condições de contraste.

Tratando-se de imagens de radiografia, van Ginneken et al. (2002) também utiliza ASM para realizar a segmentação de pulmões em imagens de radiografia no plano coronal. Em vez de utilizar perfis de tons de cinza e distância de Mahalanobis, a proposta utiliza um classificador *K-NN* (*K-Nearest Neighbors*). Para cada imagem do treinamento e para cada ponto do contorno, uma grade de $N_{grid} \times N_{grid}$ pontos é definida, sendo N_{grid} um número ímpar. O ponto do contorno é contido no centro da grade. Por exemplo, para N_{grid} , existirá um total de 25 pontos. Para cada ponto é definido um vetor de características com 60 elementos. A saída de cada vetor indica se o ponto está dentro (1) ou fora do objeto (0). Pontos do contorno são considerados pontos internos ao objeto. O conjunto de treinamento é dividido em dois subconjuntos, um para treinamento e um para validação. É usado um classificador *5-NN* com voto ponderado.

Com imagens de RM tem-se o trabalho de Ray et al. (2003), que segmenta imagens no plano coronal. Para isto diversas *Snakes* (KASS; WITKIN; TERZOPOULOS, 1988) são inicializadas no interior dos pul-

mões e vão evoluindo simultaneamente. O resultado final da segmentação é dado pela união das regiões cobertas por cada *Snake*. Para a inicialização das *Snakes* é utilizado um algoritmo padrão de detecção de bordas para obter uma segmentação grossa dos pulmões. Esta segmentação inicial é utilizada para a inicialização das *Snakes* de modo que todas fiquem em seu interior, sem tocar as bordas. O algoritmo também considera que nas imagens utilizadas os pulmões ocupam aproximadamente a mesma posição, utilizando este conhecimento para auxiliar na etapa de inicialização.


O trabalho de Lelieveldt et al. (1999) utiliza imagens de RM nos planos sagital, coronal e axial, com o objetivo de segmentar grosseiramente, mas de forma automática, coração e pulmões. Inicialmente um modelo anatômico do tórax é construído: cada órgão do tórax é modelado (a partir de uma segmentação manual) com superfícies nebulosas homogêneas. Os órgãos são agrupados hierarquicamente utilizando uma estrutura para modelagem de sólidos, chamada Geometria Sólida Construtiva (CSG, do inglês *Constructive Solid Geometry*). Este modelo é registrado com a imagem a ser segmentada levando em consideração as transições entre ar e tecido, que são definidas através de uma limiarização, cujo limiar é obtido a partir do histograma da imagem. A partir da imagem limiarizada são obtidos os pontos candidatos a borda. Estes pontos são usados como referência para fazer o registro do modelo com a imagem, etapa que pode requerer operações de translação, rotação e escala. Uma função de minimização de energia é utilizada para ajuste do modelo, resultando na segmentação final.

Dentre trabalhos de segmentação que focam especificamente em sequências de imagens de RM voltadas para reconstrução, destacam-se Asakura et al. (2005), Tavares et al. (2010), Silva et al. (2014) e Yang et al. (2014).

Asakura et al. (2005) realiza a segmentação de pulmões a partir de funções respiratórias que são obtidas a partir da representação das imagens no espaço temporal. Empilhando uma sequência temporal de

imagens de RM (Figura 24 (a)), define-se um volume espaço temporal, ou em inglês *spatiotemporal volume* (STV), definido pela função $I(x, y, t)$, onde x e y são as coordenadas de cada pixel da imagem I e t é o tempo. Considerando um plano vertical $Q_s(x_s, y_s)$, que passa por (x_s, y_s) paralelo ao eixo t (Figura 24 (b)), a intersecção deste plano com o STV define uma imagem espaço temporal (2DST). Nesta imagem é possível observar os padrões gerados pelo contorno dos pulmões, conforme mostra a Figura 24 (c). A partir da transformada de Hough e da imagem 2DST, as funções respiratórias são obtidas, como mostra a Figura 25. Uma imagem de referência é definida, segmentando manualmente os pontos do contorno dos pulmões. Cada ponto é então rastreado nas demais imagens da sequência de forma automática, a partir de sua função respiratória.


Figura 24: Formação de imagem 2DST. (a) Empilhamento de sequência de imagens de RM. (b) Corte pelo plano vertical $Q_s(x_s, y_s)$ (c) Imagem 2DST.



Fonte: Adaptado de Abe (2013, p. 24)

Tavares et al. (2010) também apresentam uma solução de segmentação baseada em funções respiratórias. A partir das imagens originais são criadas máscaras para cada imagem, a partir de 5 passos: limiarização, remoção do fundo, filtro mediana para suavizar os buracos

Figura 25: Extração de funções respiratórias. (a) Imagem 2DST tratada com operador de Sobel. (b) Espaço de Hough. (c) Funções respiratórias.



Fonte: Adaptado de Tsuzuki et al. (2009, p.576)

gerados durante a limiarização (correspondentes as regiões de veias e ramificações bronquiais), extração da maior região contínua (fundo), considerando o restante da imagem pertencente ao interior dos pulmões, e finalmente operações morfológicas que aumentam o tamanho desta região, sendo feita uma operação XOR da imagem resultante desta etapa com a imagem da etapa anterior. Assim como em Asakura et al. (2005), imagens 2DST são obtidas tanto para imagens originais quanto para as máscaras, sendo feita a interseção entre ambas, o que faz com que retem apenas 2 regiões nas 2DST originais, correspondentes ao apex e diafragma. A transformada de Hough modificada, proposta por Matsushita et al. (2004) e aprimorada por Tavares et al. (2009), é aplicada, com o objetivo de determinar a presença de padrões respiratórios em uma 2DST. Este processo é repetido para a intersecção horizontal e também para as

diagonais (-45° e $+45^\circ$). As intersecção de todas as funções respiratórias resultantes sobre uma imagem forma uma nuvem de pontos que é utilizada por um algoritmo de contornos ativos para gerar o contorno da imagem.

Silva et al. (2014) propõe um algoritmo para segmentação baseado em uma sequência de operações morfológicas para extrair a região dos pulmões. Os resultados das segmentações geram máscaras que são utilizadas para determinar com alta probabilidade a região em que o contorno dos pulmões está. Estas máscaras são utilizadas como entrada para um algoritmo baseado na transformada de Hough que então determina o contorno dos pulmões com mais precisão. Atualmente as máscaras geradas por esta técnica são utilizadas como entrada para o algoritmo de reconstrução de Abe (2013).

Yang et al. (2014) utiliza segmentação baseada em registro para segmentar volumes coronais, construindo um modelo 4D dos pulmões a partir destes volumes. Inicialmente um volume de referência é selecionado, correspondendo ao volume de posição média em relação à todos os volumes. O volume de referência é segmentado de maneira semi-automática, utilizando a ferramenta ITK-SNAP¹, baseada em algoritmos de contornos ativos. As segmentações resultantes são conferidas e ajustadas por um especialista, quando necessário. Em seguida, os demais volumes são agrupados de acordo com sua similaridade, considerando a posição do diafragma. Dentro de cada grupo, um volume de referência é selecionado. Assim, o volume de referência inicial é registrado com o volume de referencia de cada grupo e cada um destes volumes é então registrado com os demais volumes de seu grupo, necessitando poucos ajustes devido a similaridade entre os mesmos e reduzindo o custo computacional. Conforme Yang et al. (2014), o esquema apresentado pode ser utilizado por qualquer técnica de registro deformável, sendo que para seu trabalho, foi avaliado o método *Demons Registration* (THIRION, 1998).

Analizando os trabalhos estudados, percebe-se que em Leven-

¹ <http://www.itksnap.org/pmwiki/pmwiki.php>

ton, Grimson e Faugeras (2000) a segmentação utilizando *Level-Set*, acrescido de informações de forma, apresenta bons resultados para segmentação de pulmões no plano coronal em imagens obtidas por TC. Entretanto, a marcação de zonas de confiança proposta, baseada na escala de Housenfield pode apenas ser aplicada em imagens de TC. Para imagens de RM, por exemplo, não existe uma escala padrão para auxiliar na definição do limiar para cada órgão.

O trabalho de Wang e Smedby (2014) utiliza outra abordagem para indicar zonas de confiança, evitando o uso da escala de Housenfield, realizando inicialmente a segmentação da cavidade abdominopélvica, o que não é possível neste trabalho, já que as imagens disponíveis são apenas do tórax. Seguindo uma ideia semelhante, o trabalho de Okada et al. (2011) também faz a segmentação de múltiplos órgãos a partir de outros órgãos como referência, como por exemplo, a região inferior dos pulmões obtida por ASM como delimitador para a cúpula do fígado. Conforme Okada et al. (2011), apesar das diferentes condições de contraste da imagem, foi possível estabelecer este limite usando ASM. Para as imagens de RM deste trabalho, existe a desvantagem de que os pulmões são os órgãos de maior destaque na imagem, e não existem outros órgãos que possam ser utilizados como referência. Ainda assim estes trabalhos contribuem com a ideia de encontrar previamente a localização do órgão a ser segmentado, facilitando sua segmentação.

Ainda tratando-se de ASM, van Ginneken et al. (2002) também mostra que foi possível segmentar diferentes conjuntos de imagens de pulmões no plano coronal de forma automatizada, embora seja perceptível que as imagens utilizadas possuem um contraste superior em relação às imagens de RM, além de apresentar poucos ruídos em torno dos pulmões.

O trabalho de Ray et al. (2003) realiza a segmentação de pulmões em imagens de RM no plano coronal, onde *Snakes* são inicializadas dentro da região do pulmão, que é obtida por um método padrão de detecção de bordas. Neste trabalho foram testados filtros de gradiente

para tentar extrair grosseiramente a região do pulmão, como um possível local para inicialização de *Snakes*. Devido ao contraste muito baixo de algumas imagens, não foi possível obter resultados promissores para delimitar uma área de inicialização, principalmente em imagens sagitais, como mostra o exemplo da Figura 26, onde a borda dos pulmões fica quase imperceptível.

Figura 26: Segmentação de imagem usando Gradiente de Sobel: as bordas dos pulmões não ficam evidenciadas devido ao baixo contraste da imagem.



Fonte: Produção da autora, 2016.

O trabalho de Lelieveldt et al. (1999) apresenta uma proposta de segmentação totalmente automática utilizando modelos obtidos a partir de superfícies nebulosas que se adaptam à imagem de acordo com as transições entre tecido e ar. Como destacado pelo próprio autor, o resultado do método é uma segmentação grosseira, o que implica na necessidade de utilizar um método de segmentação mais refinado para obter resultados mais precisos.

Dentre os trabalhos com escopo mais próximo com esta dissertação (segmentar sequências sagitais e coronais obtidas por RM), verifica-se que em Asakura et al. (2005) existe a desvantagem de que o método apresentado não é totalmente automatizado, havendo necessidade da segmentação manual de uma imagem de referência para segmentar cada sequência de imagens.

Em Tavares et al. (2010) existe a desvantagem da utilização de uma máscara baseada em limiarização, que exige o ajuste de parâmetros, necessitando interferência manual. Além disso ainda existe o problema de que nem sempre as máscaras são geradas corretamente, o que pode impedir a extração correta das funções respiratórias.

Já em Silva et al. (2014), uma dificuldade está na segmentação de imagens coronais, que utiliza uma máscara para dividir os pulmões e limitar sua borda superior. Como esta máscara é fixa, nem sempre ela se ajusta com precisão à borda superior dos pulmões, que dependendo da sequência analisada pode estar localizada mais acima ou mais abaixo na imagem. Outra dificuldade deste método é que nem sempre os parâmetros utilizados nas operações morfológicas, como formato e tamanho do elemento estruturante, conseguem segmentar satisfatoriamente todas as sequências de imagens.

O trabalho de Yang et al. (2014), que embora trabalhe apenas no plano coronal, contribui com uma abordagem de separação de volumes em grupos conforme a posição do diafragma. De modo semelhante, nesta dissertação, as sequências de treinamento foram organizadas em grupos conforme sua posição, devido à grande diferença de forma percebida em imagens de fatias diferentes. Yang et al. (2014) também adotam a estratégia de segmentar semi-automaticamente o volume de referência, ideia que também foi utilizada para segmentar as sequências para treinamento utilizadas neste trabalho de dissertação.

Com os trabalhos estudados foi possível perceber que os métodos que utilizaram ASM se mostraram mais automatizados do que os demais, sem a necessidade de uma segmentação manual como referên-

cia ou alteração de parâmetros conforme as características das imagens, seja para a segmentação em si ou para o estabelecimento de zonas de confiança para a mesma. Ainda assim, este tipo de método tem a desvantagem de ser trabalhoso quando existem muitas imagens no conjunto treinamento, pois normalmente a segmentação deste conjunto é feita de forma manual.

Nesta dissertação é apresentada uma solução utilizando ASM para segmentar sequências sagitais e coronais de pulmões. Inicialmente HOG é utilizado para selecionar o treinamento mais adequado para a sequência a ser segmentada, uma vez que foram feitos treinamentos diferentes, já que as sequências variam bastante quanto ao tamanho e forma, dependendo de fatia em que foram extraídas. Após a seleção do treinamento a localização dos pulmões na imagem é encontrada utilizando HOG, posicionando a forma média, ponto de partida para o ASM, na posição mais adequada. A vantagem do método apresentado é que não existe o ajuste manual de parâmetros: uma vez definidos na fase de testes, estes parâmetros foram fixados e utilizados para todas as sequências. Além disso, é apresentada uma abordagem para realizar a segmentação das imagens do treinamento de forma semi-automática, a partir da segmentação manual de uma única imagem da sequência, que é utilizada para definir um marcador que serve como referência para segmentar as demais imagens utilizando Crescimento de Regiões.

4 MÉTODO PARA IDENTIFICAÇÃO E SEGMENTAÇÃO DE PULMÕES

Este capítulo está dividido em duas seções principais: a geração da base de treinamento e a segmentação automática de imagens utilizando ASM. As seções seguintes apresentam o detalhamento de cada uma destas etapas.

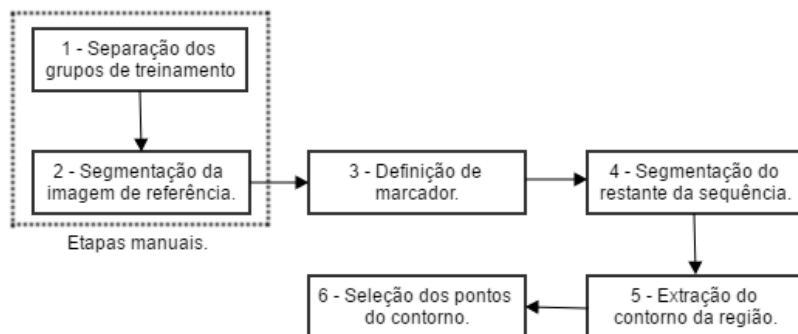
4.1 Geração da base de treinamento

Normalmente, a segmentação das imagens do conjunto de treinamento para o ASM é feita de forma manual, preferencialmente por um especialista. Como neste trabalho existem sequências de imagens para cada fatia (50 imagens por fatia), a quantidade de imagens para treinamento é grande, fazendo com que a segmentação manual ocupe muito tempo. Assim, foi identificada a necessidade de uma solução para gerar a base de treinamento de forma semi automática. A solução desenvolvida requer que o usuário segmente manualmente apenas uma imagem de cada sequência do treinamento. Para este fim é utilizada a abordagem de Crescimento de Regiões baseada em uma forma de referência. Além disso, como as imagens de cada sequência podem variar bastante em tamanho e forma de uma sequência para outra, conforme a fatia em que foram obtidas, percebeu-se a necessidade de dividir o treinamento em subgrupos, conforme o tipo de fatia. As etapas envolvidas neste processo, são resumidas pelo diagrama da Figura 27, sendo detalhadas em sequência.

4.1.1 Separação dos grupos de treinamento

Como as fatias dos pulmões podem diferir bastante umas das outras de acordo com sua posição, percebeu-se visualmente que se destacavam 6 tipos principais de fatias, tanto para imagens sagitais quanto

Figura 27: Diagrama das etapas que constituem a geração da base de treinamento.




Fonte: Produção da autora, 2016.

para imagens coronais. Desta forma as sequências foram separadas manualmente em 6 grupos, conforme sua posição. No caso de imagens sagitais a separação foi feita como segue:

- Grupo 1: fatias do início dos pulmões, onde ainda é possível visualizar partes das costelas (Figura 28 (a));
- Grupo 2: fatias dos pulmões "limpos", antes do início dos vasos sanguíneos (Figura 28 (b));
- Grupo 3: fatias onde iniciam os vasos sanguíneos (Figura 28 (c));
- Grupo 4: fatias do centro dos pulmões, cortando o coração (Figura 28 (d));
- Grupo 5: fatias do meio do coração (Figura 28 (e));
- Grupo 6: fatias do final do coração (Figura 28 (f)).

Para imagens coronais foi usada a seguinte classificação:

Figura 28: Exemplos de tipos de fatias sagitais pertencentes a cada um dos 6 grupos: (a) Grupo 1. (b) Grupo 2. (c) Grupo 3. (d) Grupo 4. (e) Grupo 5. (f) Grupo 6.




Fonte: Produção da autora, 2016.

- Grupo 1: fatias do início dos pulmões, onde o mesmo ocupa apenas uma pequena região da imagem e ainda é possível verificar partes das costelas (Figura 29 (a));
- Grupo 2: fatias dos pulmões "limpos", antes do início dos vasos sanguíneos (Figura 29 (b));
- Grupo 3: fatias onde iniciam os vasos sanguíneos (Figura 29 (c));
- Grupo 4: fatias dos pulmões na posição aproximada do centro do coração (Figura 29 (d));

- Grupo 5: fatias dos pulmões onde o coração começa a desaparecer, sendo visíveis apenas muitos vasos sanguíneos, começando a aparecer a coluna vertebral (Figura 29 (e));
- Grupo 6: fatias do final dos pulmões, onde não é mais visível o coração e a coluna vertebral é bem visível (Figura 29 (f)).

Figura 29: Exemplos de tipos de fatias coronais pertencentes a cada um dos 6 grupos: (a) Grupo 1. (b) Grupo 2. (c) Grupo 3. (d) Grupo 4. (e) Grupo 5. (f) Grupo 6.



Fonte: Produção da autora, 2016.

Desta forma, para cada paciente foi selecionada manualmente uma sequência de cada um dos seis tipos (quando disponível, uma vez que nem todos os pacientes possuem todos os 6 tipos de fatias) para ser utilizada no treinamento. Procurou-se selecionar as fatias que apresentavam um contraste melhor.

4.1.2 Segmentação de imagem de referência


Para cada sequência de imagens do treinamento foi selecionada uma imagem que foi segmentada manualmente. Foram escolhidas imagens representando os pulmões em seu estado mais inflado, assumindo que esta é a maior forma que os pulmões assumem na sequência em questão. Assim, a partir desta forma é possível criar um marcador para indicar possíveis limites para a segmentação, onde todos os outros formatos de pulmões da sequência ficam contidos dentro deste marcador.

4.1.3 Definição do marcador

Como foi percebido nos testes iniciais, conforme o Apêndice A, o método de Crescimento de Regiões apresentou os melhores resultados em imagens com poucas ramificações bronquiais e também onde havia melhor contraste entre os pulmões e caixa torácica, além de ser um algoritmo de simples implementação e de rápida execução. Em regiões de pouco contraste, a segmentação vazava para regiões que não pertenciam aos pulmões e tornar os parâmetros mais restritivos para não abrangerem estas regiões implicava que a segmentação parasse nas regiões referentes às ramificações, que se apresentam na forma de pequenos buracos mais claros no interior dos pulmões. Desta forma foi adotada uma abordagem que utilizava uma forma de referência, ou marcador, para indicar possíveis limites para a segmentação, evitando os vazamentos e também o problema de alteração de parâmetros. O marcador foi criado automaticamente aplicando uma dilatação sobre o contorno segmentado manualmente na etapa 1 (Figura 27). A região externa do marcador, correspondente à todos os pixels conectados às bordas da imagem, foi marcada com a cor azul. A região do marcador, originalmente marcada em branco após o processo de dilatação, foi marcada com a cor verde. A região interna ao marcador, originalmente preta foi mantida. A Figura 30 (a) traz um exemplo de segmentação manual de uma imagem sagital, já a figura Figura 30 (b) apresenta seu respectivo marcador. Na Figura 31 (a) é apresentada uma segmentação manual de imagem coronal, bem como

seu respectivo marcador na Figura 31 (b).

Figura 30: Exemplo de crescimento de regiões com forma de referência para sequência sagital. (a) Imagem sagital segmentada manualmente. (b) Marcador. (c) Região resultante suavizada. (d) Contorno obtido através da região segmentada.




Fonte: Produção da autora, 2016.

4.1.4 Segmentação do restante da sequência

Cada sequência foi segmentada utilizando Crescimento de Regiões e seu marcador. Para imagens sagitais foi escolhida uma semente fixa no interior dos pulmões, selecionada manualmente. Para imagens co-

Figura 31: Exemplo de crescimento de regiões com forma de referência para sequência coronal. (a) Imagem coronal segmentada manualmente. (b) Marcador. (c) Região resultante suavizada. (d) Contorno obtido através da região segmentada.



Fonte: Produção da autora, 2016.

ronais, foram selecionadas duas sementes fixas, uma para cada pulmão, também de forma manual. As sementes foram definidas por círculos de raio 3. Como critério de agregação, foram considerados pixels cujo valor fosse menor ou igual ao valor da média dos pixels que já estavam na região. Foi considerada uma vizinhança-4.

Quando um pixel analisado estava na região correspondente a região preta do marcador, as chances de pertencer ao interior dos pulmões eram altas, logo foi utilizado um critério de agregação menos restritivo: o pixel era adicionado à região se seu valor fosse menor ou igual a média dos valores dos pixels que já pertenciam à região. Se o pixel estava na região correspondente à cor verde, havia grandes chances de ele estar próximo à borda, por isso, para evitar vazamentos devido ao baixo contraste, o critério de agregação foi mais restrito, adicionando o pixel à região somente se ele tivesse valor igual ao valor do pixel vizinho que já pertencia a região. Quando o pixel estava na região correspondente a cor azul, ou seja, fora do marcador, as chances de estar fora da região de interesse eram altas, logo nenhum pixel nesta região era adicionado.

4.1.5 Extração do contorno da região

A região obtida (imagem binária) passou por uma suavização através de um filtro Gaussiano, para eliminar protuberâncias da segmentação, exemplos são mostrados nas Figura 30 (c) e Figura 31 (c). Em seguida, o contorno externo da região foi extraído. As Figura 30 (d) e Figura 31 (d) mostram os contornos resultantes.

4.1.6 Seleção dos pontos do contorno

Como o ASM requer um conjunto de pontos mais representativo do contorno, foi desenvolvido um algoritmo para selecionar estes pontos de forma automática. Para imagens coronais, por exemplo, foram selecionados 60 pontos para representar o contorno de cada pulmão. Inicialmente os testes foram iniciados com 30 pontos, porém devido ao pulmão ter uma borda irregular, principalmente quando se aproxima do coração,


percebeu-se que mais pontos seriam necessários para gerar uma borda mais suave. Assim dobrou-se o número de pontos, obtendo um resultado mais satisfatório.

A seleção de pontos foi feita separadamente para cada lado, analisando a metade correspondente da imagem, e foi feita da seguinte forma:

- a) Seleção de pontos principais (Pontos de tipo 1): foram selecionados 3 pontos principais, definidos pelo ponto mais superior do pulmão, o ponto mais próximo do canto inferior esquerdo e o ponto mais próximo do canto inferior direito (considerando a metade correspondente da imagem).
- b) Seleção de pontos secundários (Pontos de tipo 3): entre cada par de pontos principais foram selecionados pontos secundários igualmente espaçados considerando o número de pixels no segmento. A borda inferior do pulmão (dado pelo segmento entre o ponto inferior esquerdo e o ponto inferior direito) é mais lisa (sem as protuberâncias devido à presença dos ossos da caixa torácica), além de estar em uma região de melhor contraste e resultar em um segmento menor em relação aos outros dois segmentos. Assim, foram selecionados menos pontos para este segmento, totalizando 9 pontos. Entre os outros dois segmentos, que são mais longos e apresentam mais protuberâncias, foram selecionados 24 pontos. A Figura 32 mostra um exemplo de pontos selecionados em cada lado de uma imagem coronal, onde pontos em verde representam os pontos primários e os pontos em vermelho representam os pontos secundários.

Pontos de tipo 2 não foram utilizados pois a maioria dos grupos de imagens possui formato simples, com 3 pontos mais significativos, exceto no grupo 5 para sagitais e grupo 5 para coronais. Ainda assim, no grupo 5 para imagens coronais, a forma de “C” percebida no interior de cada pulmão (Figura 29) aparece apenas em uma parte das imagens.

Figura 32: Exemplo do resultado da seleção automática de pontos em imagem coronal.




Fonte: Produção da autora, 2016.

Para as imagens sagitais foi adotado o mesmo processo feito para cada pulmão, porém como já mencionado, devido as grandes diferenças de forma entre fatias diferentes, em imagens classificadas no grupos 4, 5 e 6 (Figuras 28 (d), (e) e (f)), em vez de selecionar o ponto mais próximo do canto inferior esquerdo, foi selecionado o ponto mais próximo da posição (0, 128), pois o canto inferior esquerdo do pulmão está mais próximo do meio da imagem.

4.2 Segmentação automática de imagens utilizando *Active Shape Models*

Esta seção apresenta o procedimento realizado para a segmentação automática de imagens utilizando o método ASM. Este procedimento pode ser dividido nas etapas do diagrama da Figura 33, sendo explicado a seguir.

Figura 33: Diagrama das etapas que constituem a fase de segmentação.



Fonte: Produção da autora, 2016.

4.2.1 Treinamento

Como o número de pacientes disponível na base de dados é pequeno, os treinamentos foram feitos utilizando a abordagem *leave-one-out*, que consiste em realizar o treinamento para cada paciente utilizando imagens dos demais. Assim, para cada paciente foram realizados 6 treinamentos diferentes (um para cada grupo de imagens), quando possível, pois nem todos os pacientes possuem determinados tipos de fatias, não necessitando deste tipo de treinamento neste caso. Pelo mesmo motivo, nem sempre foi possível utilizar 5 pacientes para todos os treinamentos. A Tabela 1 mostra quantas sequências (com 50 imagens cada) de diferentes pacientes foram utilizadas no treinamento de cada um dos pacientes, conforme a fatia e o tipo de imagem (sagital ou coronal).

Como os pulmões encontram-se sempre com a mesma orientação e na mesma proporção, não foi necessário fazer operações de rotação e escala sobre as imagens para obter a forma média, sendo feito apenas o alinhamento (translação) de todas as formas. Foi calculado o centro de massa de cada forma, e este foi alinhado com o centro da imagem.

Foi utilizada uma pirâmide gaussiana de imagens com apenas 2

Tabela 1: Número de pacientes utilizado no treinamento de cada paciente.

		Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5	Grupo 6
Paciente 1	Coronal	4	4	4	4	4	-
	Sagital	4	-	-	2	5	4
Paciente 2	Coronal	4	4	4	4	4	3
	Sagital	4	3	4	2	5	4
Paciente 3	Coronal	4	4	4	4	4	3
	Sagital	4	3	4	-	5	4
Paciente 4	Coronal	4	4	4	4	4	3
	Sagital	4	3	4	4	5	4
Paciente 5	Coronal	-	-	-	4	-	-
	Sagital	-	-	4	-	5	-
Paciente 6	Coronal	4	-	4	-	4	-
	Sagital	4	3	4	2	5	4

- : não foi realizado treinamento.

Fonte: Produção da autora, 2016.

níveis: para o nível 0, a imagem foi utilizada em sua resolução original. Para o nível 1, a imagem teve seu tamanho reduzido para 1/4, sendo também aplicado um filtro gaussiano com o desvio padrão $\alpha = 2$.

Os valores do parâmetro k para cada nível foram obtidos através de diferentes experimentos, que são especificados no Capítulo 5. Foi necessário usar valores diferentes para imagens sagitais e coronais, pois nas imagens sagitais, como é mostrado apenas um pulmão de cada vez, é possível obter imagens mais próximas, resultando em uma visualização maior do pulmão. Assim, para estas imagens foi utilizando um valor maior de k .

Ressalta-se ainda que no caso de imagens coronais, foram feitos treinamentos separados para cada pulmão.

4.2.2 Seleção do treinamento

Nesta etapa é preciso selecionar qual dos 6 treinamentos é mais adequado para segmentar uma sequência de imagens. Para isto o descritor HOG é aplicado sobre um conjunto de 30 imagens representado os 6 grupos (5 imagens de cada grupo). Os vetores de características deste conjunto são utilizados para treinar uma SVM multiclases, utilizando a abordagem um-contra-um. A primeira imagem da sequência a ser segmentada é então selecionada, extraindo suas características e fazendo sua classificação, verificando com qual dos grupos ela mais se assemelha, definindo qual dos 6 treinamentos será utilizado.


4.2.3 Localização dos pulmões

Na maioria das sequências de imagens da base utilizada, os pulmões se encontram próximos ao centro da imagem, como na Figura 35 (b), porém existem casos em que este está mais localizado à direita ou esquerda da imagem, ou mesmo, mais acima ou mais abaixo, como na Figura 35 (a), onde os pulmões se encontram mais para a direita da imagem e estão quase totalmente localizados na metade inferior da imagem. Assim, para encaixar a forma média no lugar mais próximo possível, evitando que o algoritmo de segmentação tenha que fazer movimentos muito largos, aumentando as chances de encontrar estruturas erradas. Também foi utilizado HOG para encontrar a localização aproximada dos pulmões.

Para as imagens sagitais foi treinado uma única SVM independente das fatias, já que elas variam mais de acordo com as estruturas internas dos pulmões do que em relação ao tamanho, diferente das fatias coronais, onde existe bastante diferença de tamanho entre uma fatia anterior e uma mais posterior. Assim, para imagens sagitais uma SVM foi treinada com 60 amostras de imagens, sendo 10 amostras positivas e 50 amostras negativas. As amostras consistem em recortes de tamanho 100x155 pixels, obtidos de várias imagens sagitais. Para amostras positivas foram feitos recortes abrangendo a região onde o pulmão era visualmente identificado, já para as amostras negativas foram recortadas

outras partes da imagem. O tamanho da janela foi escolhido de modo que fosse capaz de abranger completamente um pulmão no plano sagital. As Figuras 34 (a), (b) e (c) mostram exemplos de amostras positivas, já as Figuras 34 (d), (e) e (f) mostra exemplos de amostras negativas.


Figura 34: Exemplos de amostras usadas para treino da SVM para localização do pulmão em imagens sagitais: (a), (b) e (c) Amostras positivas. (d), (e) e (f) Amostras negativas.



Fonte: Produção da autora, 2016.

No caso das imagens coronais, foram treinadas SVMs separados para cada pulmão, já que a segmentação também foi feita em separado. Também foi necessário treinar SVMs separadas conforme os grupos, devido a diferença de tamanho entre sequências de grupos diferentes. A Figura 35 evidencia esta diferença de tamanho entre uma imagem mais inicial dos pulmões (Figura 35 (a)) e uma fatia final, já próxima da coluna do paciente (Figura 35 (b)). Foram ao todo 3 SVMs para pulmão: uma

Figura 35: Exemplos de diferentes formas de pulmões em um mesmo paciente. (a) Fatia inicial. (b) Fatia final do mesmo paciente.



Fonte: Produção da autora, 2016.

SVM para o primeiro e segundo grupos, uma para o terceiro e quarto grupos e uma para o quinto e sexto grupos. Para cada um deles foram utilizadas 30 amostras, sendo 10 positivas e 20 negativas.

Além de serem selecionadas a partir de sequências diferentes, as amostras para cada SVM, também possuem tamanhos distintos, conforme a sequência e também conforme o pulmão (esquerdo ou direito). A Tabela 2 apresenta os diferentes tamanhos de janelas utilizados. Na SVM 1, que corresponde aos grupos 1 e 2, ou seja, para fatias mais iniciais, foram utilizados valores diferentes para cada lado, uma vez que no pulmão esquerdo (visualmente, no lado direito da imagem) está presente o coração, logo o pulmão possui um tamanho menor em relação ao outro lado. Isto já não ocorre em fatias mais posteriores, próximas da coluna, onde o coração é menos visível ou totalmente invisível.

Nas imagens sagitais as janelas são percorridas sobre toda a imagem, varrendo a imagem a cada 10 pixels. Este mesmo valor é usado nas imagens coronais, porém nestes casos como é procurado apenas um pulmão de cada vez, a imagem é percorrida até a metade + 20 pixels, para o lado esquerdo da imagem, e da metade - 20 pixels até o fim para o

Tabela 2: Valores de janelas utilizados para as SVMs para as imagens coronais, conforme o pulmão.

	Tamanho da janela (em pixels)	
	Esquerdo	Direito
SVM 1	110x180	110x170
SVM 2	140x90	140x90
SVM 3	140x90	140x90

Fonte: Produção da autora, 2016.

lado direito da imagem, uma vez que nem sempre os pulmões estão bem centralizados.

Existem casos de a detecção ocorrer em mais de uma janela. Nessas situações é obtida uma janela média. Vale ressaltar também que, como em um mesmo grupo, os pulmões não aparecem com variações de escala significantes, não houve a necessidade de fazer a varredura das imagens em múltiplas escalas.

4.2.4 Posicionamento da forma média sobre a localização dos pulmões

A etapa de localização dos pulmões foi feita para a primeira imagem de cada sequência apenas, pois dentro de uma mesma sequência os pulmões não tem sua posição alterada, o que muda é apenas seu tamanho, conforme o instante da respiração em que a imagem foi obtida. Assim, para cada imagem da sequência a ser segmentada, é possível utilizar a posição encontrada na primeira imagem e posicionar a forma média sobre esta posição. Isto é feito da seguinte maneira: a etapa de localização dos pulmões retorna o centro da janela em que ocorreu a detecção. É calculado então o centro da forma média obtida no treinamento. Para isto é criada uma janela envolvente em torno da forma média, cujo canto superior esquerdo corresponde ao menor valor em x e menor valor em y ; o canto inferior esquerdo corresponde ao menor valor em x e

maior valor em y ; o canto superior direito corresponde ao maior valor em x e menor valor em y ; e o canto inferior direito corresponde ao maior valor em x e maior valor em y . O centro desta janela é calculado e é então alinhado sobre o centro da janela de detecção.

4.2.5 Aplicação do ASM

Após a definição da posição de partida para a forma média, é iniciada a segmentação utilizando ASM. Conforme apresentado no Capítulo 5, seção 5.1.2, foi utilizada uma pirâmide de imagens de 2 níveis. Os valores para os parâmetros k , m e f_v foram obtidos por meio de testes com diferentes valores. O procedimento para sua obtenção, bem como os valores utilizados são apresentados no Capítulo 5, seção 5.1.3. O critério de parada utilizado consistiu em analisar a movimentação dos pontos da última iteração com a iteração anterior: se 90% dos pontos ou mais (Pontos de tipo 1) não tivesse sua posição alterada, então a busca era encerrada, aplicando PCA para ajustar a forma padrão dos pulmões. A PCA foi aplicada na última iteração de cada nível da pirâmide.

5 TESTES E RESULTADOS

Este capítulo apresenta os diferentes testes que foram realizados com o intuito de definir os melhores parâmetros para a segmentação das sequências de pulmões. O capítulo também apresenta os resultados obtidos com a solução proposta.

5.1 Testes para definição de parâmetros

As imagens de RM desta base foram obtidas pelo equipamento Siemens 1.5T Symphony MRI, usando o método *Fast Imaging with Steady-State Precession* (FISP). A base é formada por cerca de 8000 imagens, contendo imagens de 6 pacientes saudáveis não fumantes, com idades entre 24 e 58 anos. Cada paciente contém sequências sagitais e coronais, com 50 imagens por sequência. A Tabela 3 relaciona o número de sequências de cada paciente, considerando que algumas sequências possuíam uma qualidade muito baixa e não foram usadas.

As Figuras 36 (a) e 37 (a) mostram exemplos de imagens descartadas devido ao seu baixo contraste, que torna difícil a identificação dos


Tabela 3: Sequências por paciente.

Paciente	Número de sequências		
	Sagitais	Coronais	Total
1	9	10	19
2	16	18	34
3	18	28	46
4	17	23	40
5	4	2	6
6	22	5	27
Total	86	86	172

Fonte: Produção da autora, 2016.

contornos dos pulmões mesmo visualmente. Já as Figuras 36 (b) e 37 (b) trazem exemplos de fatias que interseccionam as bordas do pulmão, onde existe uma maior presença dos ossos das costelas do que dos próprios pulmões.

Figura 36: Exemplos de sequências sagitais descartadas: (a) Baixo contraste. (b) Fatia muito próxima das costelas.



Fonte: Hospital Kanagawa (2004-2006)

A base foi disponibilizada no formato DICOM, sendo que as imagens foram convertidas para o formato JPEG (*Joint Photographic Experts Group*) para serem processadas. Para a conversão foi utilizado o software MicroDicom¹, que possui recursos como visualização e conversão de arquivos DICOM. As imagens possuem resolução de 256x256 pixels.


Os testes foram realizados em um microcomputador com sistema operacional Windows® , com 6GB de memória RAM (*Random Access Memory*) e processador Intel® Core™ i5-3317U CPU de 1.70GHz. Os algoritmos usados nos testes foram implementados em Python (versão 2.7.10). Foram utilizadas as seguintes bibliotecas:

a) NumPy² versão 1.9.2: para as operações com matrizes;

¹ <http://www.microdicom.com/>

² <http://www.numpy.org/>

Figura 37: Exemplos de sequências coronais descartadas: (a) Baixo contraste. (b) Fatia muito próxima das costelas.



Fonte: Hospital Kanagawa (2004-2006)

- b) Modulo Scikit-learn versão 0.11.3 e scikit-image versão 0.17 da toolkit Scikits³, para trabalhar com SVM e HOG, respectivamente;
- c) Pacote Ndimage versão 2.0 da biblioteca SciPy⁴, utilizado para operações morfológicas e cálculo de centro de massa, entre outros;
- d) Pacote Spatial da biblioteca Scipy para cálculos de distância, como a distância de Mahalanobis.

Os tópicos a seguir descrevem o processo da definição dos parâmetros utilizados.

5.1.1 Definição do sentido de busca


Para o perfil de tons de cinza para cada ponto, assim como a reta de tamanho $2m + 1$ onde o mesmo seria procurado, foi adotado o sentido

³ <https://scikits.appspot.com/>

⁴ <https://www.scipy.org/>

de dentro para fora, como mostra a Figura 38. Este sentido foi adotado após a verificação de testes utilizando os dois sentidos. Nos testes utilizando as retas no sentido de fora para dentro, muitas vezes, em vez de detectar a borda dos pulmões corretamente, a segmentação detectou a borda do corpo do paciente, como mostra a Figura 39, correspondente a primeira iteração do algoritmo sobre uma imagem sagital.

Figura 38: Sentido do perfil de tons de cinza e da reta para busca.




Fonte: Produção da autora, 2016.

5.1.2 Definição da pirâmide de imagens

As imagens utilizadas possuem resolução de 256x256 pixels. Assim, inicialmente foi definida uma pirâmide de imagem com 3 níveis: nível 0 com a resolução original, nível 1 com resolução 181x181 pixels e nível 2 com 128x128 pixels. Testes mostraram que resoluções inferiores foram ineficientes. Em imagens coronais de sequências iniciais dos pulmões, por exemplo, estes possuem extremidades finas, onde muitas vezes, mesmo um valor de k pequeno como 2 ou 3 pixels, acaba atravessando os pulmões em vez de abranger apenas as informações das bordas. Assim, a resolução de 128x128 pixels foi definida como nível mais alto da pirâmide. Durante os testes, foi verificada uma boa convergência ainda no nível 2, percebendo que uma resolução intermediária entre o ní-

Figura 39: Testes buscando o padrão no sentido de fora para dentro em imagem do nível 1 (imagem ampliada para melhor visualização).




Fonte: Produção da autora, 2016.

vel 2 e o nível 0 não contribuiu com muitas melhorias. Assim, optou-se por eliminar este nível, passando a considerar como nível 0 a resolução original e como nível 1 a resolução de 128x128 pixels, reduzindo o número de iterações.


5.1.3 Definição dos parâmetros k , m e fv

A escolha do valor de k depende do objeto a ser segmentado. A Figura 40, mostra as consequências de um valor de k muito pequeno ($k = 5$, considerando a imagem no nível 0, ou seja, em sua resolução original). Este valor de k consegue representar a variação de intensidade característica do contorno dos pulmões (Figura 40) (a), porém também existem pequenas estruturas dentro dos pulmões que podem ser representadas por este mesmo valor de k (Figura 40 (b)), o que pode fazer com que durante a busca do modelo de tons de cinza, o algoritmo encontre estas pequenas estruturas em vez de encontrar corretamente o contorno do pulmões.

Figura 40: Definição do parâmetro k . (a) Exemplo de escolha de $k = 5$, representando a borda de um pulmão. (b) Mesmo valor de k , representando uma estrutura interna com variação de níveis de cinza semelhante à borda.



(a)



(b)

Fonte: Produção da autora, 2016.

Os parâmetros k e m foram selecionados empiricamente. Para o nível 1 da pirâmide foram feitos testes utilizando valores para k a partir de 2, sendo incrementados de 1 em 1 pixel. Para o nível 0, o k foi iniciado com o dobro do valor do k para o nível 1, sendo também incrementado de 1 em 1 pixel. Os valores selecionados são mostrados na Tabela 4, pois levaram a melhores resultados na maioria das imagens. Os valores de m foram iniciados sendo o dobro do valores de k , nos respectivos níveis, sendo incrementados de 1 em 1 pixel, sendo apresentados na Tabela 5.

Tabela 4: Valores utilizados para k .

Tipo de Fatia	Tamanho de k (em número de pixels)	
	Nível 1	Nível 0
Sagital	4	8
Coronal	3	6

Fonte: Produção da autora, 2016.

Tabela 5: Valores utilizados para m .

Tipo de Fatia	Tamanho de m (em número de pixels)	
	Nível 1	Nível 0
Sagital	10	16
Coronal	6	12

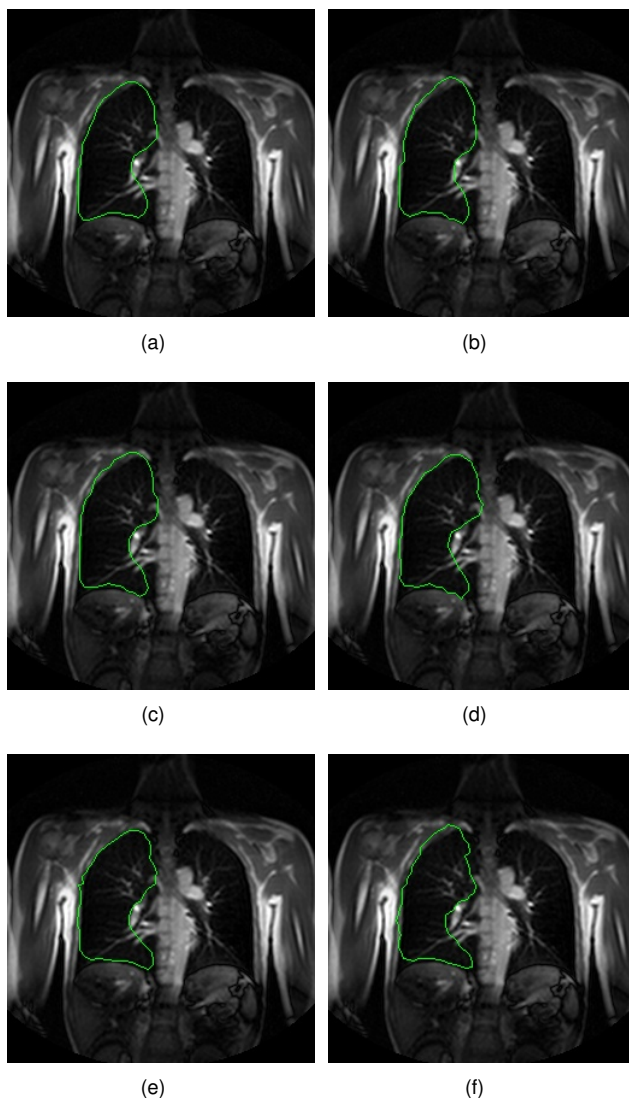
Fonte: Produção da autora, 2016.

Assim como k e m , o valor fv foi obtido empiricamente. Conforme van Ginneken et al. (2002), este valor costuma variar entre 0,9 e 0,995 (entre 90% e 99,5%). Assim, foram realizados testes nessa faixa de valores. A Figura 41 compara exemplos da segmentação de uma imagem coronal utilizando estes valores, sendo que em alguns casos, valores ligeiramente diferentes trouxeram resultados visivelmente iguais, como por exemplo, na Figura 41 (a), que mostra o resultado obtido utilizando valores de 0,900 a 0,910, uma vez que esta faixa de valores gerou o mesmo

resultado. A Figura 41 (b) apresenta o resultado obtido para valores entre 0,915 e 0,945. A Figura 41 (c) exhibe os resultados para valores entre 0,950 e 0,970. A Figura 41 (d) mostra o resultado para valores entre 0,975 e 0,985. A Figura 41 (e) apresenta o resultado para o valor 0,990 e a Figura 41 (f) mostra o resultado para o valor 0,995.

Na Figura 41 (e) é possível ver que o valor de $fv = 0,990$ trouxe resultados mais precisos do que com valores menores. Nestes casos, a segmentação não conseguiu alcançar o canto inferior direito do pulmão. Com um fv igual à 0,995, mostrado na Figura 41 (f), os resultados foram próximos, embora um pouco menos precisos, e a segmentação foi menos suave.

Figura 41: Exemplos de segmentação de imagem coronal com diferentes valores de fv : (a) 0,900; 0,905 e 0,910. (b) 0,915; 0,920; 0,925; 0,930; 0,935; 0,940 e 0,945. (c) 0,950; 0,955; 0,960; 0,965 e 0,970. (d) 0,975; 0,980 e 0,985. (e) 0,990. (f) 0,995.



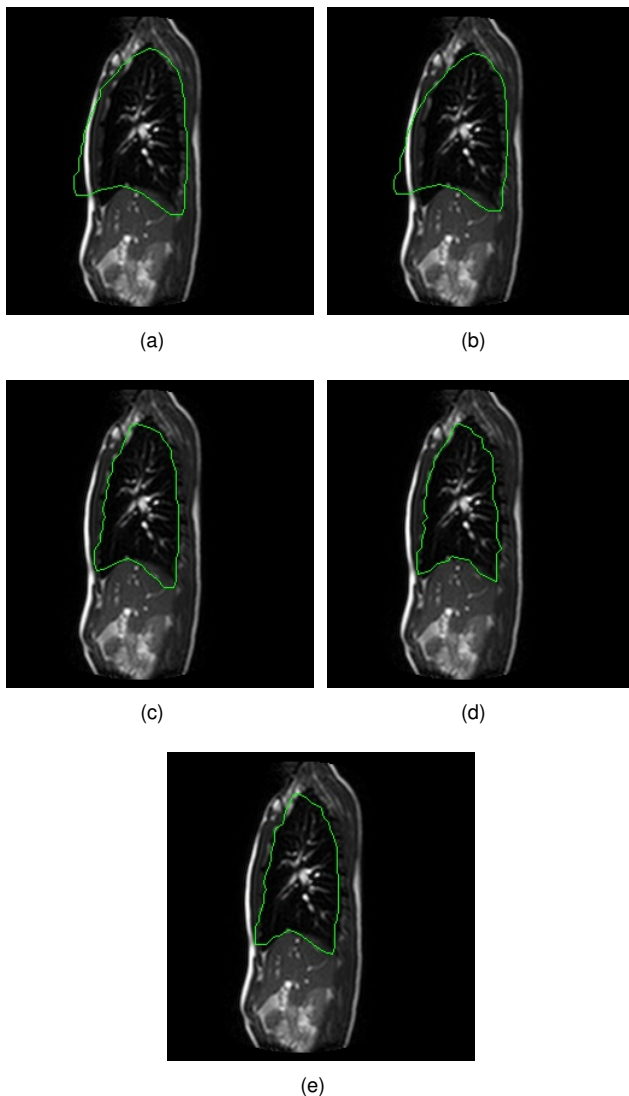
Fonte: Produção da autora, 2016.

A Figura 42 apresenta os resultados dos testes feitos com imagens sagitais. A Figura 42 (a) mostra o resultado para o valor de 0,900. A Figura 42 (b) apresenta o resultado para valores entre 0,905 e 0,950. A Figura 42 (c) exibe os resultados para valores de 0,955 a 0,980. A Figura 42 (d) mostra o resultado obtido com o valor 0,990 e a Figura 42 (e) apresenta o resultado para o valor 0,995.

É possível verificar que para o caso das imagens sagitais a diferença de valores é ainda mais visível. Valores inferiores à 0,955 levaram a uma segmentação bastante imprecisa como mostram as Figuras 42 (a) e (b), pois não conseguem representar todas as características do conjunto de treinamento, fazendo com que a etapa de PCA aproxime a segmentação de algo mais próximo da própria forma média. Os resultados melhores também foram obtidos com um $fv = 0,990$ para a grande maioria dos casos, como mostra o exemplo da Figura 42 (d). Com um fv maior, igual à 0,995, os resultados já não foram tão precisos.

Desta forma, como o valor de $fv = 0,990$ trouxe melhores resultados na maioria dos casos tanto para imagens coronais quanto sagitais, este foi o valor definido como padrão para a segmentação.

Figura 42: Exemplos de segmentação de imagem sagital com diferentes valores de fv : (a) 0,900. (b) 0,905; 0,910; 0,915; 0,920; 0,925; 0,930; 0,935; 0,940; 0,945 e 0,950. (c) 0,955; 0,960; 0,965; 0,970; 0,975 e 0,980. (d) 0,990. (e) 0,995.



Fonte: Produção da autora, 2016.

5.2 Resultados do método proposto


Em geral, o grupo de treinamento foi selecionado de forma correta, errando em poucos casos. A detecção da localização dos pulmões também foi satisfatória na maioria dos casos. Assim, a forma média foi posicionada sobre um local bem próximo aos pulmões, sendo necessário uma média de 3 iterações durante no nível 1 da pirâmide e 2 iterações no nível 0. A Figura 43 mostra uma segmentação de uma imagem sagital realizada passo-a-passo. Para facilitar a visualização, nos resultados apresentados, os pontos do contorno dos pulmões foram ligados com segmentos de reta para formar um contorno fechado.

A Figura 44 mostra mais exemplos de segmentações finais em imagens sagitais e a Figura 45 mostra exemplos de segmentações em imagens coronais. Elas representam a maioria dos resultados obtidos: as segmentações conseguem representar a forma dos pulmões com coerência, entretanto as segmentações não apresentam muita precisão, principalmente em bordas com ângulos mais acentuados ou em regiões com contraste muito baixo, entre outros problemas descritos a seguir.


5.3 Problemas encontrados

Em alguns casos a segmentação não se mostrou precisa, como no caso das regiões próximas do coração, em imagens coronais, onde existe um contorno mais irregular. Um exemplo é apresentado na Figura 46. Um fator que pode ter influenciado esta falta de precisão é o fato de as imagens do treinamento terem sido segmentadas automaticamente, o que pode levar a erros. No caso da segmentação manual, o especialista determina cada ponto do contorno no local mais adequado. Na segmentação automática pode ocorrer o problema de alguns pontos não ficarem exatamente sobre a borda, como é o caso da Figura 47, onde o canto inferior esquerdo ficou um pouco distante da borda, adicionando pixels mais escuros à parte do perfil de tons de cinza que deveria ter pixels mais claros, sendo que o oposto também pode acontecer.


Figura 43: Passo-a-passo da segmentação de uma imagem sagital: (a) Localização dos pulmões. (b) Posicionamento da forma média sobre a janela onde foi feita a detecção. (c) Resultado da primeira iteração do ASM no nível 0. (d) Resultado da segunda iteração do ASM no nível 0. (e) Aplicação de PCA. (Continua).




(a)




(b)



(c)




(d)




(e)

Figura 43: Passo-a-passo da segmentação de uma imagem sagital: (f) Projeção do resultado do nível 1 no nível 0. (g) Resultado da primeira iteração do ASM no nível 0. (h) Resultado da segunda iteração do ASM no nível 0. (i) Aplicação de PCA - Resultado final. (Continuação).



Fonte: Produção da autora, 2016.


Figura 44: Exemplo de segmentações em imagens sagitais.



Fonte: Produção da autora, 2016.

Os demais problemas encontrados são principalmente consequência a pouca quantidade de pacientes disponíveis na base de dados, o que levou a treinamentos com no máximo 5 pacientes. Além disso existe uma falta de padronização para a aquisição das imagens: os pacientes tem diferentes quantidades de sequências e nem todos os pacientes possuem sequências das mesmas fatias. Assim em muitos casos, houve treinamentos utilizando apenas sequências de 3 pacientes, o que levou a segmentações insatisfatórias. A Figura 48 (a) mostra um exemplo de segmentação cujo treinamento contou com imagens de apenas 2 pacientes.

Figura 45: Exemplo de segmentações em imagens coronais.




Fonte: Produção da autora, 2016.

É possível perceber que a forma encontrada ficou bem distante da forma desejada, já que o treinamento conhecia apenas 2 tipos de forma, mostradas nas Figuras 48 (b) e (c).

Mesmo onde foi possível utilizar mais pacientes para um treinamento (até 5 pacientes), esta variedade de pacientes ainda se mostrou pequena. Em caso de pacientes com pulmões muito diferentes dos demais, o algoritmo até consegue mover a maioria dos pontos corretamente em direção às bordas, porém a aplicação de PCA acaba ajustando a

Figura 46: Exemplo de imprecisão rente ao contorno do coração.



Fonte: Produção da autora, 2016.

forma encontrada para algo conhecido pelo treinamento, levando também a uma segmentação incorreta. A Figura 49 traz um exemplo onde a Figura (a) foi segmentada utilizando um treinamento com imagens de outros 4 pacientes, exemplificadas nas Figuras (b) - (e). É possível verificar que as imagens do treinamento possuem pulmões mais compridos e estreitos do que os pulmões segmentados, que possuem uma forma mais curta e larga. Outro exemplo é apresentado na Figura 50 (a), que contou com 3 pacientes no treinamento, sendo que os pulmões das imagens de treinamento possuem uma forma mais curta do que os pulmões do paciente. O algoritmo conseguiu detectar as bordas entre a caixa torácica corretamente, porém, em imagens onde os pulmões estavam mais inflados, o

Figura 47: Exemplo de imprecisão na segmentação automática de imagem de treinamento.




Fonte: Produção da autora, 2016.

algoritmo detectou uma forma menor do que a esperada.

Outro problema em relação a falta de informação no treinamento é que cantos mais acentuados geralmente são suavizados após aplicação de PCA, mesmo quando o algoritmo detecta estas as bordas corretamente. A Figura 51 destaca este problema.

Um problema detectado ocasionalmente é quanto a detecção de falsas bordas. Uma vez que padrão procurado pelo ASM é dado pela variação de tons de cinza da borda e não pelos tons de cinza em si, as vezes ele pode detectar outra região que tenha uma variação de tons de cinza parecida com a de uma borda. No caso de pulmões, este padrão é uma faixa de pixels escuros, próximos do preto, seguida de uma faixa de pixels

Figura 48: Exemplos de segmentação incorreta utilizando 2 pacientes no treinamento. (a) Segmentação resultante. (b) e (c) Exemplos de imagens dos 2 pacientes usados no treinamento.




Fonte: Produção da autora, 2016.


mais claros, próximos do cinza, caracterizando uma transição brusca de níveis de cinza. Este mesmo tipo de transição pode ocorrer, dependendo da imagem, no limite inferior do fígado, onde é possível verificar, como na Figura 52, pixels mais escuros, na faixa de cinza, seguidos de pixels mais claros, na faixa do branco, que também descrevem uma transição brusca de tons de cinza. No exemplo, o algoritmo detectou esta borda do fígado em vez de detectar a borda dos pulmões, que devido ao baixo contraste possuía uma transição mais suave. Com a aplicação de PCA, a forma foi ajustada para se aproximar ainda mais de um pulmão, porém ainda é possível perceber como ela se aproxima em direção à região da borda do fígado.

Devido aos problemas mencionados, não foi possível utilizar a segmentação anterior para segmentar a próxima imagem, pois na maioria das vezes, devido a pouca quantidade de informações do treinamento, em algum momento acontece uma segmentação imprecisa ou incorreta, que consequentemente leva a uma segmentação imprecisa para o restante das imagens. A Figura 53 mostra na coluna esquerda (Figura 53 (a), (c) e (e)), segmentações realizadas sem utilizar a segmentação an-


Figura 49: Exemplos de segmentação incorreta utilizando 4 pacientes no treinamento. (a) Segmentação resultante. (b) - (e) Exemplos de imagens do treinamento.




(a)




(b)



(c)




(d)



(e)

Fonte: Produção da autora, 2016.

Figura 50: Exemplos de segmentação incorreta utilizando 3 pacientes no treinamento. (a) Segmentação resultante. (b) - (d) Exemplos de imagens do treinamento.




Fonte: Produção da autora, 2016.

terior como ponto de partida. Já na coluna direita (Figura 53 (b), (d) e (f)) são mostradas segmentações utilizando a segmentação anterior como ponto de partida. É possível perceber pela coluna direita que uma segmentação pouco precisa usada como referência, levou à segmentações ainda mais imprecisas. Isto não é percebido na coluna esquerda onde, erros da segmentação anterior não influenciam a próxima.


Outro problema em usar a segmentação anterior como ponto de partida é que também existem sequências onde é verificada uma variação bastante significativa entre duas imagens seguidas dentro da sequência, como no exemplo apresentado na Figura 54.

Figura 51: Exemplo de imprecisão em cantos acentuados.




Fonte: Produção da autora, 2016.

Figura 52: Exemplo de detecção de borda falsa.




Fonte: Produção da autora, 2016.

Figura 53: Comparação de resultados utilizando segmentação anterior e sem utilizar segmentação anterior. (a), (c) e (e): Imagens em sequência segmentadas sem utilizar a segmentação anterior. (b), (d) e (f): Imagens em sequência segmentadas utilizando a segmentação anterior.



Fonte: Produção da autora, 2016.

Figura 54: Variação brusca na posição do diafragma em imagens próximas. (a) Imagem de uma sequência coronal. (b) Próxima imagem da sequência.



Fonte: Hospital Kanagawa (2004-2006).

O Apêndice B mostra mais exemplos das segmentações obtidas, onde são mostradas exemplos de segmentação para cada sequência de 5 pacientes.


5.4 Avaliação dos resultados

A base de imagens utilizada não possui imagens segmentadas por um especialista. Assim, para fazer uma avaliação dos resultados obtidos, os resultados gerados automaticamente neste trabalho foram comparados com os resultados gerados pelo método semi-automático proposto por Silva et al. (2014), que atualmente é utilizado para gerar as entradas para o trabalho de reconstrução de Abe (2013). Dentre as sequências segmentadas utilizando o método de Silva et al. (2014), foram selecionadas 8 sequências (400 imagens) sagitais e 6 sequências (300 imagens) coronais, correspondentes aos melhores resultados e que pertencessem aos mesmos grupos de treinamento definidos no Capítulo 4, Seção 4.1.

Para as imagens sagitais foram classificadas sequências pertencentes ao grupo 3, uma vez que sequências deste grupo apresentaram melhores resultados, devido as características das imagens, que não possuem muitas estruturas internas, além de ser o grupo com maior incidência de sequências. Imagens de fatias mais posteriores, onde o coração e veias são mais visíveis, apresentaram resultados menos precisos, mesmo com ajustes de parâmetros, como na Figura 55 (a).

Para imagens coronais também foram selecionadas sequências do grupo 3, devido a maior incidência de sequências deste grupo e também visto que elas apresentavam um contraste melhor, minimizando vazamentos. Além disso em imagens posteriores onde mais veias ou ramificações bronquiais eram visíveis, em algumas imagens da sequência a segmentação enfrentava problemas, principalmente no lado do coração, como mostra a Figura 55 (b), onde a segmentação omitiu uma parte do pulmão.

Figura 55: Exemplo de segmentações incorretas utilizando o método de Silva et al. (2014): (a) Imagem sagital. (b) Imagem coronal.



Fonte: Produção da autora, 2016.


As imagens selecionadas foram então comparadas com os re-

sultados obtidos neste trabalho. Para isso foi utilizado o Coeficiente de Similaridade de Dice (DSC) (DICE, 1945). Dada duas segmentações, A e B, o DSC é definido como: $DSC(A, B) = 2(|A| \cap |B|) / (|A| + |B|)$. O resultado deste cálculo é um valor no intervalo de $[0, 1]$. Assim, quanto mais o resultado se aproxima de 1, maior a similaridade entre as duas segmentações.

Para imagens sagitais foi obtida uma média de $0,87 \pm 0,02$, sendo que cerca de 89% das imagens obtiveram um coeficiente maior que 0,85. Apenas uma imagem teve coeficiente inferior a 0,80, mostrada na Figura 56, que apresenta um exemplo de imagem segmentada com o método de Silva et al. (2014) (Figura 56 (a)), uma imagem segmentada pelo método utilizado nesta dissertação (Figura 56 (b)) e a intersecção entre ambas (Figura 56 (c)), onde a cor vermelha representa a segmentação obtida com o método de Silva et al. (2014), a cor verde representa a segmentação obtida neste trabalho e a cor amarela representa a área de intersecção entre as duas. Para esta imagem foi obtido o menor coeficiente, igual a 0,79. É possível perceber que neste caso a segmentação usando o método de Silva et al. (2014) apresenta uma maior precisão na região diafragmática, comparado ao método utilizado neste trabalho, onde os cantos dos pulmões sofrem arredondamentos conforme discutido na Seção 5.3, levando a uma diferença entre as segmentações. Outro fator importante é que com o método de Silva et al. (2014), diferente do método apresentado neste trabalho, a segmentação abrange até mesmo as regiões mais escuras entre as vértebras, onde existe dúvida em relação a esta região pertencer ou não aos pulmões, contribuindo também para uma maior diferença entre as segmentações.

Para imagens coronais foram obtidos resultados inferiores, com uma média de $0,78 \pm 0,04$, sendo que cerca de 7% das imagens obteve coeficientes acima de 0,85. A Figura 57 apresenta um exemplo de imagem segmentada com o método de Silva et al. (2014) (Figura 57 (a)), uma imagem segmentada pelo método utilizado nesta dissertação (Figura 57 (b)) e a intersecção entre ambas (Figura 57 (c)). Para esta imagem foi

Figura 56: Comparação de resultados para imagem sagital. (a) Segmentação de imagem sagital utilizando o método de Silva et al. (2014). (b) Segmentação utilizando o método proposto. (c) Interseção entre as segmentações (a) e (b).




Fonte: Produção da autora, 2016.

obtido o menor coeficiente, igual à 0,63. Além da diferença gerada pelos arredondamentos das extremidades dos pulmões usando o método proposto neste trabalho, que acontecem em ambos os lados dos pulmões, também é possível perceber na Figura 57 (a), que utiliza o método de Silva et al. (2014), a presença de vazamentos na região de baixo contraste entre os pulmões e os demais órgãos, além de bordas mais "quadradas", contribuindo também para uma diferença entre as duas segmentações.

Analisando as imagens, é possível perceber que as diferenças entre as segmentações, em geral, acontecem devido ao fato de métodos bastante diferenciados serem utilizados. O método proposto por Silva et al. (2014) é baseado em morfologia matemática, não sofrendo com arredondamentos, e por vezes gerando bordas mais "serrilhadas", conforme o tamanho do elemento estruturante utilizado. Já o método apresentado nesta dissertação utiliza PCA ao final de cada segmentação para aproximar a forma dos pulmões. Além disso, utiliza um treinamento baseado em imagens segmentadas semi-automaticamente utilizando crescimento de regiões, sendo que após este processo as imagens são suavizadas para evitar bordas serrilhadas. Desta maneira, um novo teste foi realizado utilizando as imagens geradas pelo método de Silva et al. (2014) para o treinamento do ASM, verificando se o método proposto poderia chegar a resultados mais próximos aos de Silva et al. (2014).

Assim, as sequências selecionadas resultantes do método de Silva et al. (2014) foram utilizadas no treinamento para o ASM (por isso a preferência por selecionar sequências do mesmo grupo). Uma vez que algumas segmentações apresentaram problemas semelhantes aos da Figura 55, dentro de cada sequência foram selecionadas 40 boas segmentações que foram então utilizadas no treinamento. O conjunto de pontos de cada contorno foi definido automaticamente, utilizado a abordagem apresentada na Subseção 4.1.6. Os treinamentos foram então aplicados na segmentação das próprias sequências, uma vez que objetivo deste teste não era verificar a robustez do treinamento, mas sim verificar as

Figura 57: Comparação de resultados para imagem coronal. (a) Segmentação de imagem coronal utilizando o método de Silva et al. (2014). (b) Segmentação utilizando o método proposto. (c) Interseção entre as segmentações (a) e (b).




Fonte: Produção da autora, 2016.

diferenças nos resultados gerados utilizando o conjunto de treinamento segmentado semi-automaticamente neste trabalho, e o treinamento que utilizou as segmentações geradas pelo método de Silva et al. (2014), podendo assim analisar a eficiência do método proposto para a geração do conjunto de treinamento.

Para imagens sagitais foi obtida uma média de $0,88 \pm 0,03$, sendo que 88% das imagens obtiveram um coeficiente maior que 0,85 e apenas 1,75% das imagens obteve coeficientes inferiores à 0,80. A Figura 58 faz um comparativo com a mesma imagem apresentada na Figura 55, onde é possível perceber que embora o ASM ainda execute uma suavização nas bordas com a aplicação de PCA (as segmentações não adentram a região da coluna), foi possível obter cantos mais precisos com o novo treinamento, levando a um coeficiente de 0,88 para esta imagem, que anteriormente apresentou um coeficiente de 0,79. Ainda assim, fazendo uma análise da média geral obtida, é possível verificar uma melhora muito pequena em relação aos resultados gerados utilizando o conjunto de treinamento segmentado semi-automaticamente neste trabalho, mostrado que apesar de gerar imagens de treinamento com cantos mais suavizados, este mostrou um resultado praticamente tão eficiente quanto um treinamento gerado com imagens segmentadas pelo método de Silva et al. (2014).

Para as imagens coronais, as segmentações resultantes utilizando imagens segmentadas pelo método de Silva et al. (2014) no treinamento, não foram satisfatórias, detectando com bastante imprecisão as bordas dos pulmões, como no exemplo da Figura 59. Isso ocorreu pois muitas vezes o método de Silva et al. (2014) sofre com pequenos vazamentos ou cantos mais "quadrados", que consequentemente não ficam exatamente sobre a borda dos pulmões, como na Figura 55 (b), ressaltando que o objetivo do método não é gerar segmentações refinadas, mas segmentações com grande probabilidade de pertencerem aos pulmões. Isso implicou em modelos de níveis de cinza incorretos em uma grande quantidade de imagens, levando à segmentações imprecisas. Assim, as


Figura 58: Comparação de resultados para imagem sagital utilizando resultados de Silva et al. (2014) no treinamento. (a) Segmentação de imagem sagital utilizando o método de Silva et al. (2014). (b) Segmentação utilizando ASM baseado em treinamento feito com as segmentações de Silva et al. (2014). (c) Interseção entre as segmentações (a) e (b).



Fonte: Produção da autora, 2016.

segmentações obtidas utilizando o treinamento baseado no método de Silva et al. (2014) não foram consideradas viáveis para realizar uma comparação.

Figura 59: Segmentação imprecisa de imagem coronal utilizando as segmentações de Silva et al. (2014) para treinamento do ASM.



Fonte: Produção da autora, 2016.

6 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho propôs uma solução para a segmentação automática de sequências de imagens sagitais e coronais de pulmões humanos, obtidas por RM, que ainda é uma área pouco explorada tratando-se deste tipo de imagem. O método apresentado propõe uma solução para segmentação semiautomática do conjunto de treinamento, utilizando crescimento de regiões com um marcador, necessitando que apenas uma imagem de cada sequência do treinamento seja segmentada manualmente. Devido à grande diferença de forma e tamanho percebida nos pulmões conforme a fatia em que as sequências foram obtidas, foi verificada a necessidade de separar o treinamento em grupos, totalizando 6 treinamentos diferentes, conforme os tipos de fatia. Na etapa de segmentação, HOG foi utilizado para verificar a similaridade de uma sequência de entrada com cada um dos 6 grupos de treinamento, definindo o treinamento mais adequado para realizar sua segmentação. HOG foi utilizado também para detectar a localização dos pulmões na imagem, iniciando o método ASM a partir do local mais apropriado. Diversos testes foram conduzidos de modo a identificar os melhores parâmetros tanto para treinamento quanto para segmentação, definindo parâmetros fixos que funcionassem eficientemente para todas as sequências.

Esta abordagem se mostrou capaz de segmentar eficientemente sequências de 5 diferentes pacientes sem a necessidade de ajuste de parâmetros, diferente dos outros métodos que foram testados ao longo do trabalho. Estes métodos, além de requererem ajustes de parâmetros, sofreram com o baixo contraste das imagens, que ocasionou vazamentos nas segmentações, além de serem mais propícios a ficarem presos em estruturas internas aos pulmões. O método proposto possibilitou segmentações automáticas e também teve estes problemas contornados, uma vez que é baseado em ASM. O ASM já parte de uma forma média baseada em um treinamento, que representa uma possível localização dos

pulmões, assim apenas ajustes sobre esta forma precisam ser feitos, sem a necessidade de percorrer as regiões mais problemáticas das imagens, como o interior dos pulmões, que contém uma grande quantidade de pequenas estruturas.

A utilização do HOG para detectar a localização aproximada dos pulmões mostrou-se uma etapa importante, uma vez que permitiu que o ASM fosse iniciado de um local próximo aos pulmões, exigindo uma média de apenas 5 iterações. O mesmo também mostrou eficiência ao ser utilizado na detecção do treinamento mais adequado para segmentar cada sequência.

Outra contribuição do trabalho foi a proposta de uma solução semi-automática para realizar a segmentação das imagens de treinamento para o ASM, que requer a intervenção humana apenas para segmentar uma imagem de cada sequência usada no treinamento, evitando a segmentação manual de centenas de imagens.

O método proposto para segmentação semi automática das imagens de treinamento se mostrou eficiente, sendo que a partir de uma única silhueta segmentada manualmente para cada sequência, o método teve a capacidade de gerar o marcador, segmentar o restante das imagens, extrair suas silhuetas e selecionar um conjunto de pontos mais representativos para cada imagem, de forma totalmente automatizada. Desta forma foi possível gerar o conjunto de treinamento de forma rápida, empregando mais tempo nos testes utilizando ASM. Além disso, este método viabiliza a rápida inserção de mais sequências para o treinamento futuramente.

O ASM apresentou resultados promissores em casos onde foi possível usar um maior número de pacientes para treinamento (4 ou 5 pacientes), e quando os pulmões em questão não apresentavam uma forma muito diferente dos pulmões nas imagens de treinamento. Nestes casos foi possível detectar formas bem próximas dos pulmões, embora ainda se verifique uma imprecisão nas segmentações nos cantos, que forma um ângulo mais acentuado, ou em áreas próximas do coração. Apesar disso,

acredita-se que isto não seja um problema, pois as segmentações resultantes serão utilizadas por trabalhos que fazem a reconstrução 4D dos pulmões com o objetivo de representar o movimento respiratório e não a forma dos pulmões precisamente. Para casos onde foram usados 2 ou 3 pacientes no treinamento, os resultados não foram bons. Um exemplo recorrente é a detecção de uma forma menor do que a real forma dos pulmões, uma vez que as imagens segmentadas apresentavam pulmões com tamanhos menores do que os pulmões conhecidos pelo treinamento.

Outro problema encontrado foi a falta de padronização na obtenção das imagens disponibilizadas na base, já que existem pacientes que possuem várias sequências e pacientes que possuem apenas algumas sequências. Além disso, nem todos os pacientes possuem sequências referentes a fatias bastante significativas, como por exemplo, fatias sagitais do centro dos pulmões.

Devido a estes problemas foi possível perceber a importância de uma base de imagens diversificada para realizar o treinamento do ASM, pois embora para cada fatia exista um total de 50 imagens, estas imagens são bastante próximas entre si, apresentado apenas alterações em relação ao tamanho, especialmente na região do diafragma. Assim, mesmo utilizando até 250 imagens em cada treinamento (quando era possível realizar treinamentos com 5 pacientes), a diversidade destas imagens ainda era pequena. Como é possível perceber pelas imagens desta base, os pulmões são órgãos que além de apresentar variações de tamanho durante a respiração, apresentam uma geometria bastante diferenciada entre diferentes pacientes.

Ainda assim, foi possível verificar em imagens sagitais que cerca de 89% dos resultados comparados com os resultados de Silva et al. (2014), cujo método é atualmente utilizado para gerar as imagens de entrada para o algoritmo de reconstrução proposto por Abe (2013), apresentaram coeficientes de similaridade acima de 0,85, sendo que a média foi de $0,87 \pm 0,02$. Para imagens coronais foi obtida uma média de $0,78 \pm 0,04$, porém apenas 7% das imagens ficou com coeficientes maiores

que 0,85. Acredita-se que estes resultados inferiores para imagens coronais tenham acontecido pois o método de Silva et al. (2014) mostrou uma precisão inferior para imagens coronais em relação às sagitais, lembrando que o método em questão visa gerar regiões com grande probabilidade de pertencerem aos pulmões, e não uma segmentação refinada. Também foi verificado que mesmo utilizando o método de segmentação semi-automático proposto neste trabalho para geração da base de treinamento, que gerava bordas mais suaves nos cantos dos pulmões, os resultados foram bem próximos dos resultados obtidos utilizando as segmentações de Silva et al. (2014) para treinamento. Analisando estas duas abordagens, foi verificado que a primeira apresentou uma média de similaridade de $0,87 \pm 0,02$ e a segunda, $0,88 \pm 0,03$, considerando imagens sagitais, sendo que imagens coronais não apresentaram resultados eficientes utilizando as segmentações de Silva et al. (2014) no treinamento, inviabilizando a comparação.

Em trabalhos futuros pretende-se obter mais imagens, conseguindo fazer um treinamento mais robusto, evitando os diversos problemas encontrados devido à uma base com pouco número de pacientes. Assim, espera-se obter segmentações mais precisas, capazes de representar mais características dos pulmões. Desta forma, deve ser possível utilizar informações temporais para tornar o processo de segmentação de uma sequência mais rápido, utilizando a segmentação anterior como ponto de partida para a próxima. A utilização de segmentações manuais feitas por especialistas também é uma tarefa importante a ser realizada no futuro, a fim de permitir uma comparação mais precisa dos resultados através da comparação destas segmentações manuais com as obtidas pelo método automático. Também devem ser realizados outros testes no intuito de obter melhorias para o método, sendo eles:

- Testar a utilização de filtros para melhorar o contraste entre os pulmões e a caixa torácica, evitando evidenciar as estruturas internas;
- Utilizar pontos secundários nas formas mais complexas, tanto em

imagens sagitais quanto coronais;

- Utilizar mais pontos na região do diafragma, tentando encontrar suas bordas com mais precisão, uma vez que o diafragma é o principal responsável pela variação de forma dos pulmões durante a respiração;
- Utilizar informações de outros órgãos como referência para localização dos pulmões, como por exemplo, o coração, que apresenta um contraste melhor;
- Eliminar pontos que ficam em posições muito distantes de seus vizinhos devido a erros (*outliers*) antes da aplicação de PCA, garantindo que a forma final não seja influenciada por erros;
- Estudar outras maneiras de segmentar automaticamente todas as sequências, independente de uma separação de grupos de acordo com a fatia;
- Avaliar outros métodos de detecção além do HOG, verificando se estes podem ser mais eficientes na detecção de uma localização mais precisa.

REFERÊNCIAS BIBLIOGRÁFICAS

ABE, L. I. **Reconstrução da Superfície Diafragmática em Movimento a Partir de Múltiplas Sequências Coronais e Sagitais Temporais de Ressonância Magnética**. Dissertação (Mestrado) — Escola Politécnica da Universidade de São Paulo, São Paulo, 2013.

ALEGRO, M. C. **Segmentação de Tumores do Encéfalo em Imagens por Ressonância Magnética Baseada em Informações Texturais**. Dissertação (Mestrado) — Escola Politécnica da Universidade de São Paulo, São Paulo, 2009.

ALVAREZ, L.; BAUMELA, L.; HENRIQUEZ, P.; MARQUEZ-NEILA, P. Morphological snakes. In: **Proceedings of IEEE Conference on Computer Vision and Pattern Recognition**. San Francisco, CA: [s.n.], 2010. p. 2197–2202.

ASAKURA, A.; GOTOH, T.; KAGEI, S.; IWASAWA, T.; INOUE, T. Computer aided system for respiratory motion analysis of the lung region by sequential mr images. **Medical Imaging Technology**, v. 22, p. 39–46, 2005.

BIEDERER, J. General requirements of mri of the lung and suggested standard protocol. In: _____. **MRI of the Lung**. [S.l.]: Springer-Verlag Berlin Heidelberg, 2009. p. 3–16.

BOOKSTEIN, F. L. **Morphometric Tools for Landmark Data**. [S.l.]: Cambridge University Press, 1991.

BRADSKI, G.; KAEHLER, A. **Learning OpenCV**. 1^a. ed. Gravenstein Highway North, Sebastopol, CA: O'Reilly Media, 2008.

COOTES, T. An introduction to active shape models. In: _____. **Image Processing and Analysis**. Oxford: University Press, 2000. p. 223–248.

COOTES, T. F.; TAYLOR, C. J.; COOPER, D. H.; GRAHAM, J. Active shape models: Their training and application. **Computer Vision and Image Understanding**, v. 61, n. 1, p. 38–59, 1995.

CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, v. 20, n. 3, p. 273–297, 1995.

COSTA, E. L. V.; LIMA, R. G.; AMATO, M. B. P. Electrical impedance tomography. **Current Opinion in Critical Care Journal**, v. 15, n. 1, p. 18–24, 2009.

DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. In: **Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)**. San Diego, CA: [s.n.], 2005. p. 886 – 893.

DICE, L. R. Measures of the amount of ecologic association between species. **Ecology**, v. 26, p. 297–302, 1945.

DOUGHERTY, E. D.; LOTUFO, R. A. **Hands-on Morphological Image Processing**. 1ª. ed. Bellingham, Washington: SPIE Press, 2003.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. [S.l.]: John Wiley & Sons, 2001.

GARIB, D. G.; RAYMUNDO, R.; RAYMUNDO, M. V.; RAYMUNDO, D. V.; FERREIRA, S. N. Tomografia computadorizada de feixe cônico (cone beam): entendendo este novo método de diagnóstico por imagem com promissora aplicabilidade na ortodontia. **Revista Dental Press de Ortodontia e Ortopedia Facial**, v. 12, n. 2, p. 139–153, 2007.

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

HOSPITAL KANAGAWA. **Imagens cedidas pela Universidade de São Paulo**. 2004–2006.

IWASAWA, T.; KAGEI, S.; GOTOH, T.; YOSHIIKE, Y.; MATSUSHITA, K.; KURIHARA, H.; SAITO, K.; MATSUBARA, S. Magnetic resonance analysis of abnormal diaphragmatic motion in patients with emphysema. **European Respiratory Journal**, v. 19, n. 2, p. 225–231, 2002.

JOLLIFFE, I. **Principal Component Analysis**. 2ª. ed. New York: Springer, 2002.

KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: Active contour models. **International Journal of Computer Vision**, v. 1, n. 4, p. 321–331, 1988.

LEITE, C. C.; AMARO, E. J.; OTADUY, M. G. **Radiologia Convencional**. 2015. Disponível em: <http://portaldaradiologia.com/?page_id=538#none>. Acesso em: Mar. 2015.

LELIEVELDT, B. P. F.; GEEST, R. J. van der; REZAEI, M. R.; BOSCH, J. G.; REIBER, J. H. C. Anatomical model matching with fuzzy implicit surfaces for segmentation of thoracic volume scans. **IEEE Transactions on Medical Imaging**, v. 18, n. 3, p. 218–230, 1999.

LEVENTON, M. E.; GRIMSON, W. E.; FAUGERAS, O. Statistical shape influence in geodesic active contours. In: **Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2000**. Hilton Head Island, SC: [s.n.], 2000. p. 1316–1323.

MA, Y.; GUO, G. **Support Vector Machines Applications**. 1^a. ed. [S.l.]: Springer International Publishing, 2014.

MASSELLI, I. V.; WU, D. S. K.; PINHEDO, H. A. **Manual básico de ultrassonografia**. [S.l.], 2013. Disponível em: <http://ddi.unifesp.br/media/uploads/educacao_e_pesquisa/graduacao/manual_basico_ultrassonografia.pdf>. Acesso em: 11.5.2015.

MATSUSHITA, K.; ASAKURA, A.; KAGEI, S.; GOTOH, T.; IWASAWA, T.; INOUE, T. Shape tracking on chest mr sequence images using respiratory patterns. **The Journal of the Institute of Image Electronics Engineers of Japan**, v. 33, p. 1115–1122, 2004.

MILLS, G. H.; WILD, J. M.; EBERLE, B.; BEEK, E. J. R. V. Functional magnetic resonance imaging of the lung. **British Journal of Anaesthesia**, v. 91, n. 1, p. 16–30, 2003.

OKADA, T.; LINGUARIU, M. G.; ; YOSHIDA, Y.; HORI, M.; SUMMERS, R. M.; CHEN, Y. W.; TOMIYAMA, N.; SATO, Y. Abdominal multi-organ segmentation of ct images based on hierarchical spatial modeling of organ interrelations. In: _____. **Abdominal Imaging. Computational and Clinical Applications**: Third international workshop, held in conjunction with miccai 2011, toronto, on, canada, september 18, 2011, revised selected papers. Toronto: Springer, 2011. p. 173–180.

OKUNO, E. Efeitos biológicos das radiações ionizantes: acidente radiológico de goiânia. **Estudos Avançados**, v. 27, n. 77, p. 185–199, 2013.

OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man and Cybernetics**, v. 9, n. 1, p. 62–66, 1979.

RAY, N.; ACTON, S. T.; ALTES, T.; LANGE, E. E. de; BROOKEMAN, J. R. Merging parametric active contours within homogeneous image regions

for mri-based lung segmentation. **IEEE Transactions on Medical Imaging**, v. 22, n. 2, p. 189–199, 2003.

ROGOWSKA, J. Overview and fundamentals of medical image segmentation. In: _____. **Handbook of Medical Image Processing and Analysis**. 2^a. ed. San Diego: Academic Press, 2009. p. 73–90.

ROSE, J. L.; REVOL-MULLER, C.; ALMAJDUB, M.; CHEREUL, E.; ODET, C. Shape prior integrated in automated 3d region growing method. In: **Proceedings of IEEE International Conference on Image Processing**. San Antonio, TX: [s.n.], 2007. p. 53–56.

SETHIAN, J. A. **Level Set Methods and Fast Marching Methods**. [S.l.]: Cambridge University Press, 1999.

SHOJAILI, R.; ALIREZAIE, J.; BABYN, P. Automatic lung segmentation in ct images using watershed transform. In: **Proceeding of IEEE International Conference on Image Processing**. Genova: [s.n.], 2005. p. 1270–1273.

SILVA, A. G.; TSUZUKI, M. S. G.; ROSSO JUNIOR, R. S. U.; KAGEI, S.; GOTOH, T.; IWASAWA, T. Lung segmentation of sagittal and coronal mr images using morphological operations. In: **Proceedings of Biosignals and Biorobotics Conference (2014): Biosignals and Robotics for Better and Safer Living**. Salvador: [s.n.], 2014. p. 1–5.

TAIRA, R. K.; IGLESIAS, J. E.; JAHANSHAD, N. Characterizing imaging data. In: _____. **Medical Imaging Informatics**. 1^a. ed. [S.l.]: Springer US, 2010. p. 197–255.

TAVARES, R. S.; SATO, A. K.; TSUZUKI, M. S. G.; GOTOH, T.; KAGEI, S.; ASAKURA, A.; IWASAWA, T. Temporal segmentation of lung region mr image sequences using hough transform. In: **Proceedings of the 32nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society**. Buenos Aires: [s.n.], 2010. p. 4789–4792.

TAVARES, R. S.; TSUZUKI, M. S. G.; GOTOH, T.; KAGEI, S.; IWASAWA, T. Lung movement determination in temporal sequences of mr images using hough transform and interval arithmetics. In: **Proceedings of the 7th IFAC Symp on Modelling and Control in Biomedical Systems**. Aalborg: [s.n.], 2009. p. 192–197.

THAI, L. H.; TRUONG, V. N. Face alignment using active shape model and support vector machine. **International Journal of Biometrics and Bioinformatics**, v. 4, n. 6, p. 224–234, 2012.

THIRION, J. P. Image matching as a diffusion process: An analogy with maxwell's demons. **Medical Image Analysis**, v. 2, p. 243–260, 1998.

TSUZUKI, M. S. G.; TAKASE, F. K.; GOTOH, T.; KAGEI, S.; ASAKURA, A.; IWASAWA, T.; INOUE, T. Animated solid model of the lung constructed from unsynchronized mr sequential images. **Computer Aided Design**, v. 41, n. 8, p. 573–585, 2009.

VAN GINNEKEN, B.; FRANGI, A. F.; STAAL, J. J.; ROMENY, B. M. T. H.; VIERGEVER, M. A. Active shape model segmentation with optimal features. **IEEE Transactions on Medical Imaging**, v. 21, n. 8, p. 924–933, 2002.

VIOLA, P.; JONES, M. J. Robust real-time face detection. **International Journal of Computer Vision**, v. 2, n. 57, p. 137–154, 2004.

WANG, C.; SMEDBY, O. Automatic multi-organ segmentation using fast model based level set method and hierarchical shape priors. In: **Proceedings of the VISCERAL Organ Segmentation and Landmark Detection Benchmark at the 2014 IEEE International Symposium on Biomedical Imaging**. Beijing: [s.n.], 2014. p. 1316–1323.

YANG, Y.; VAN REETH, E.; POH, C. L.; TAN, C. H.; THAN, I. W. K. A spatiotemporal-based scheme for efficient registration-based segmentation of thoracic 4-d mri. **IEEE Journal of Biomedical and Health Informatics**, v. 18, n. 3, p. 969–977, 2014.

APÊNDICE A – TESTES INICIAIS

Antes da seleção do ASM como solução para o problema apresentado, foram feitos diversos testes com métodos de segmentação aplicados a imagens médicas, encontrados na literatura, como Limiarização, Operações Morfológicas, Crescimento de Regiões, *Watershed*, *Snakes* e *Level-Sets*.

A limiarização é um método simples e um dos mais utilizados na segmentação de imagens, conforme a literatura analisada, sendo muitas vezes utilizado como um etapa de pré segmentação para outros métodos. Foi adotado o seguinte critério para binarizar as imagens, considerando $f(x, y)$ o valor de um pixel da imagem original e $g(x, y)$ o valor do pixel após a limiarização:

$$g(x, y) = \begin{cases} \text{Branco}, & \text{se } f(x, y) \geq 80 \\ \text{Preto}, & \text{se } f(x, y) < 80 \end{cases}$$

O limiar $T = 80$ foi definido empiricamente, apresentando um resultado mais satisfatório do que aplicando o limiar de Otsu ((OTSU, 1979)). Nas fatias coronais 60 (a) e 61 (a) foi possível eliminar a maior parte do ruído fora dos pulmões, porém as regiões claras, resultantes das ramificações dos brônquios e dos vasos sanguíneos, ficaram mais evidentes. O mesmo aconteceu com a sagital da 62 (a).

Os testes com Operações Morfológicas foram feitos baseando-se no algoritmo apresentado por Silva et al. (2014). A principal desvantagem percebida foi devido ao uso de uma máscara fixa em imagens coronais, independente da sequência de imagens, que não se ajustou bem em sequências onde os pulmões estavam mais abaixo na imagem como mostra a Fig. 61 (b), não delimitando com precisão seu limite superior. Na Fig. 60 (b) onde a máscara se ajustou melhor obteve-se uma segmentação mais satisfatória. Também notou-se que na maioria das ima-

gens não foi possível obter um limite entre pulmões, mesmo com o uso da máscara. Já nas imagens sagitais, algumas partes dos pulmões não foram incluídas na segmentação, principalmente as regiões mais claras, como na Fig.62 (b). Além disso houve a necessidade de alterar parâmetros conforme a sequência de imagens, como por exemplo o tamanho do elemento estruturante utilizado.

A técnica de Crescimento de Regiões ((ROGOWSKA, 2009)) foi testada utilizando uma semente fixa (um disco de raio 3) para cada pulmão, no caso de imagens coronais. Foram adicionados à região pixels com valor inferior ou igual a média dos pixels que já pertenciam à região, considerando uma vizinhança-4. Foram obtidos bons resultados com esta técnica em imagens com pouca presença de ramificações bronquiais, como mostra a Fig. 60 (c). Já na Fig. 61 (c), a grande presença de ramificações pode ser percebida como pequenos buracos brancos bastante próximos que formam uma espécie de barreira e impedem o crescimento da região. O mesmo problema ocorre nas imagens sagitais (62 (c)), que em sua maioria apresentam muitas ramificações bronquiais, além do baixo contraste entre pulmões e caixa torácica.

Para os testes com *Watershed* ((ROGOWSKA, 2009)) foi utilizada a biblioteca Mahotas¹ na versão 1.4.0. O *Watershed* foi aplicado sobre o gradiente de Sobel das imagens. Os testes sempre resultaram em imagens supersegmentadas, como é mostrado nas Fig. 60 (d) e Fig. 61 (d), para imagens coronais, e na Fig. 62 (d) para imagens sagitais, uma vez que cada pequena região branca provocada pelas ramificações bronquiais acaba resultando em uma bacia. De acordo com a literatura, normalmente, o *watershed* não é utilizado puramente, mas sim aplicado em imagens com marcadores, que podem limitar possíveis regiões para as bordas. Neste trabalho, seria necessário uma etapa de pré-segmentação para determinar estes marcadores, utilizando outros métodos de segmentação, que não haviam mostrado bons resultados até o respectivo momento desta pesquisa.

¹ <http://mahotas.readthedocs.org/en/latest>

Foram realizados também testes com *Snakes* ((KASS; WITKIN; TERZOPOULOS, 1988)), sendo utilizada a biblioteca disponibilizada por Alvarez et al. (2010)². Foram definidas sementes fixas para cada pulmão, com a *snake* evoluindo de dentro para fora. Também foi utilizada uma linha branca vertical para definir o limite entre os dois pulmões. Assim como no Crescimento de Regiões, foram obtidos resultados satisfatórios em imagens com poucas ramificações bronquiais, como na Fig. 60 (e), porém os mesmos parâmetros não geraram bons resultados em imagens com mais ramificações como na Fig. 61 (e). O mesmo aconteceu nas imagens sagitais como no exemplo da Fig. 62 (e).


Para os testes com *Level-Set* ((SETHIAN, 1999)) foi utilizada a biblioteca SimpleITK³ na versão 0.9.1. Para imagens coronais, para cada pulmão foi definida uma semente fixa para iniciar a evolução do contorno, no sentido de dentro para fora. Foram encontrados problemas semelhantes aos encontrados com Crescimento de Regiões e *Snakes*. Nas imagens coronais com menos ramificações foram obtidos resultados melhores, como mostra a Fig. 60 (f). Já para as figuras que apresentavam mais ramificações, o desenvolvimento correto do método foi limitado, como mostra a Fig. 61 (f). Ainda é possível ver que na tanto na Fig. 60 (f) quanto na Fig. 61 (f) que a segmentação vazou. Isto aconteceu ao tornar os parâmetros de segmentação menos restritivos na tentativa de evitar que a mesma parasse de desenvolver nas regiões claras. Em imagens sagitais foi verificado o mesmo tipo de problema conforme a Fig. 62 (f).

Visto que com limiarização foi possível eliminar a maioria do ruído fora dos pulmões nas imagens coronais, estas imagens foram aproveitadas para criar uma máscara para a aplicação de *Snakes*, no sentido fora para dentro, evitando o problema gerado pelas ramificações bronquiais. Um bom resultado foi obtido criando uma máscara da seguinte forma: foi aplicada sobre as imagens binarizadas uma abertura morfológica 10x10, seguida de uma suavização por filtro Gaussiano. Sendo assim, para cada

² <http://github.com/pmneila/morphsnakes>

³ <http://www.simpleitk.org>

Figura 60: Boas segmentações de imagens coronais: (a) Limiarização. (b) Operações Morfológicas. (c) Crescimento de Regiões. (d) *Watershed*. (e) *Snake*. (f) *Level-set*.

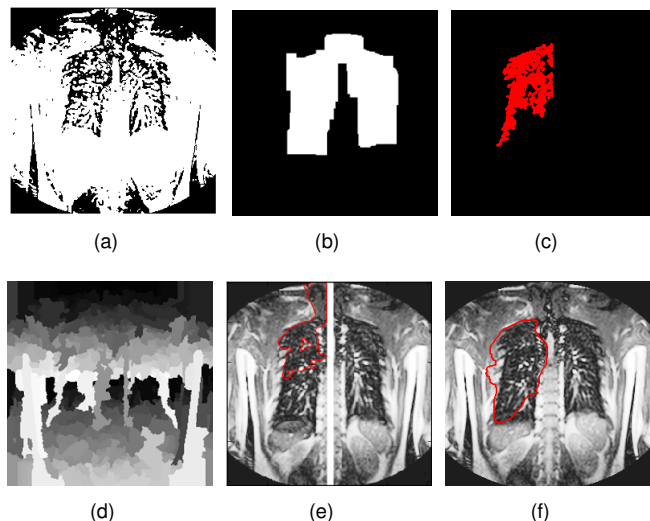


Fonte: Produção da autora, 2016.

imagem foi gerada uma máscara, usando ela própria como referência, como por exemplo, na Figura 63 (a). Assim como é sugerido por Silva et al. (2014), também foi utilizada uma máscara para dividir os pulmões e evitar que a segmentação se perdesse na região da garganta, que contém uma faixa de pixels escuros com valores próximos ao valor dos pixels dos pulmões. Esta máscara é apresentada pela Figura 63 (b).

As duas máscaras foram aplicadas sobre a imagem original. Exemplos do resultado são apresentados na Figura 64. Foi iniciada então uma *Snake*, desta vez utilizado como semente um círculo centrado em (120, 100), de raio 120, evoluindo o contorno de fora para dentro, ao contrário do primeiro teste. Alguns resultados são mostrados na Figura 65. Os resultados foram promissores, embora ainda seja possível notar a interferência do uso de uma máscara fixa, como mostra a Figura 65 (b), onde

Figura 61: Segmentações ruins de imagens coronais: (a) Limiarização. (b) Operações Morfológicas. (c) Crescimento de Regiões. (d) *Watershed*. (e) *Snake*. (f) *Level-set*.




Fonte: Produção da autora, 2016.

ainda parte da região escura da garganta foi incluída na segmentação.

Apesar dos bons resultados com imagens coronais, não foi viável aplicar esta estratégia em imagens sagitais, visto que a limiarização não gerou bons resultados que pudessem ser aproveitados para a criação de uma máscara eficiente. Sua aplicação apenas ressaltou algumas regiões mais claras fora dos pulmões sem trazer benefício algum na identificação do limite do mesmo, como é mostrado na Figura 66


É possível perceber que a maioria dos métodos sofreu com problemas como o baixo contraste entre os pulmões e a região do fígado ou mesmo entre os pulmões e a caixa torácica, que muitas vezes possui tons de cinza muito próximos aos dos pulmões. Este tipo de problema levou a vazamentos na maioria dos testes. Outro problema é a grande quantidade de pequenas regiões mais claras dentro da imagem, resultado de veias

Figura 62: Segmentações de imagens sagitais: (a) Limiarização. (b) Operações Morfológicas. (c) Crescimento de Regiões. (d) *Watershed*. (e) *Snake*. (f) *Level-set*.




Fonte: Produção da autora, 2016.

Figura 63: Máscaras utilizadas. (a) Máscara gerada pela imagem resultante da limiarização seguida de abertura morfológica e suavização. (b) Máscara usada para dividir os pulmões e eliminar interferência da região da garganta.




Fonte: Produção da autora, 2016.

Figura 64: Exemplos de resultados da aplicação das máscaras da Figura 63.



Fonte: Produção da autora, 2016.

Figura 65: Exemplo da aplicação de *Snakes* Morfológicas de fora para dentro sobre imagens que utilizam máscara.




Fonte: Produção da autora, 2016.

e ramificações bronquiais, que funcionaram como uma barreira, impedindo que a segmentação encontrasse algumas regiões que pertencem aos pulmões.

Outra dificuldade foi que a maioria dos métodos necessitou de ajustes de parâmetros (Limiarização, Operações Morfológica, *Snakes* e *Level-Sets*), pois os parâmetros usados para uma sequência nem sempre funcionam para as demais. Embora no Crescimento de Regiões e *Watershed* não tenha sido feito este tipo de ajuste, ambos sofreram bastante com o baixo contraste e também com as estruturas mais claras no

Figura 66: Aplicação de máscara ineficiente para imagens sagitais. (a) Exemplo de máscara obtida por limiarização e suavização sobre imagem sagital. (b) Resultado da adição da máscara obtida com a imagem original.



Fonte: Produção da autora, 2016.

interior dos pulmões.

Considerando estes problemas, foram iniciados os estudos com ASM, que realiza um treinamento para gerar um modelo do objeto de interesse, tentando então ajustá-lo sobre a imagem a ser segmentada, diferente de métodos como Crescimento de Regiões, *Snakes* e *Level-Sets*, por exemplo, que partem de uma semente no interior dos pulmões, ou mesmo métodos baseados em Limiarização, Operações Morfológicas e *Watershed*, que são bastante suscetíveis a encontrarem as ramificações bronquiais no interior dos pulmões, que se tornam um problema para a segmentação na maioria das vezes.

APÊNDICE B – SEGMENTAÇÕES

As imagens apresentadas mostram um exemplo de segmentação de cada sequência de 5 pacientes (1, 2, 4, 5, e 6). O paciente 3, possuía pulmões muito diferenciados dos demais. Enquanto os outros pulmões tinham uma forma mais estreita e comprida, os pulmões do paciente 5 eram mais largos e curtos. Assim, o algoritmo não conseguiu reconhecer corretamente estes pulmões na grande maioria das imagens, como o exemplo da Figura 49.


Os treinamentos utilizados para segmentar cada sequência foram selecionados automaticamente pela SVM. Em seguida são apresentados os resultados de uma segmentação de cada sequência dos 5 pacientes, destacando o treinamento utilizado para cada uma delas e o número de pacientes disponível no treinamento. Treinamentos que constam como não realizados não foram feitos, por o paciente não ter aquele tipo de fatia ou por nos demais pacientes não existirem aquele tipo de fatia para realizar o treinamento.

B.1 Paciente 1

Exemplos de sequências sagitais (Figura 67) e sequências classificadas em cada treinamento:

- a) Treinamento 1 - 4 pacientes: (a);
- b) Treinamento 2 - não realizado;
- c) Treinamento 3 - não realizado;
- d) Treinamento 4 - 3 pacientes: (h);
- e) Treinamento 5 - 5 pacientes: (e) a (g);
- f) Treinamento 6 - 4 pacientes: (b) a (d).

Figura 67: Paciente 1: Exemplos de cada sequência sagital.



Fonte: Produção da autora, 2016.

Exemplos de sequências coronais (Figura 68) e sequências classificadas em cada treinamento:

- a) Treinamento 1 - 4 pacientes: (a);
- b) Treinamento 2 - 4 pacientes: nenhuma sequência;
- c) Treinamento 3 - 4 pacientes: (b);
- d) Treinamento 4 - 5 pacientes: (c) a (e);
- e) Treinamento 5 - 5 pacientes: (f) a (h);
- f) Treinamento 6 - não realizado.

B.2 Paciente 2


Exemplos de sequências sagitais (Figura 69) e sequências classificadas em cada treinamento:

- a) Treinamento 1 - 4 pacientes: (a) e (b);
- b) Treinamento 2 - 3 pacientes: (c) a (f) e (o) a (q);
- c) Treinamento 3 - 4 pacientes: (g) e (h);
- d) Treinamento 4 - 3 pacientes: (j)
- e) Treinamento 5 - 5 pacientes: (i), (k) e (l);
- f) Treinamento 6 - 4 pacientes: (m) e (n).

Exemplos de sequências coronais (Figura 70) e sequências classificadas em cada treinamento:

- a) Treinamento 1 - 4 pacientes: (a) a (c);
- b) Treinamento 2 - 4 pacientes: (d);
- c) Treinamento 3 - 4 pacientes: (e);
- d) Treinamento 4 - 5 pacientes: (f) e (g);
- e) Treinamento 5 - 5 pacientes: (h);
- f) Treinamento 6 - 4 pacientes: (i) a (k).

Figura 68: Paciente 1: Exemplos de cada sequência coronal.



Fonte: Produção da autora, 2016.

Figura 69: Paciente 2: Exemplos de cada sequência sagital (Continua).



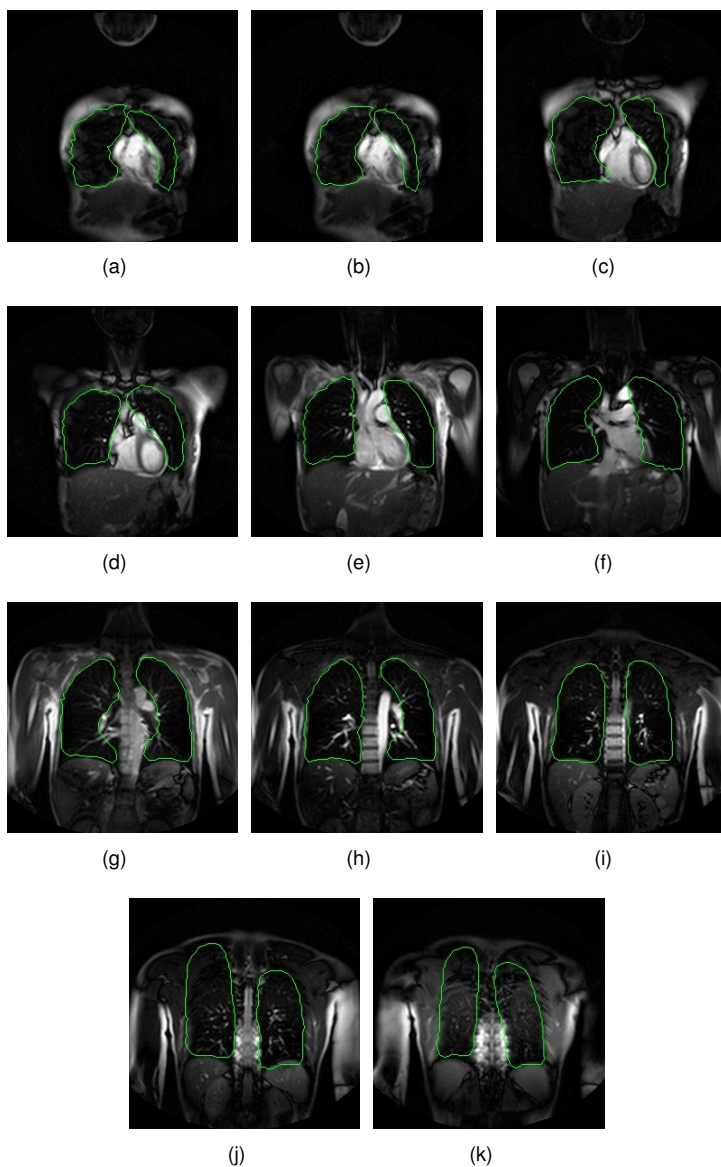


Figura 69: Paciente 2: Exemplos de cada sequência sagital (Conclusão).



Fonte: Produção da autora, 2016.

Figura 70: Paciente 2: Exemplos de cada sequência coronal.



Fonte: Produção da autora, 2016.

B.3 Paciente 4

Exemplos de sequências sagitais (Figura 71) e sequências classificadas em cada treinamento:

- a) Treinamento 1: nenhuma sequência;
- b) Treinamento 2 - 3 pacientes: (a) a (d);
- c) Treinamento 3 - 4 pacientes: (e) a (g);
- d) Treinamento 4 - 3 pacientes: não realizado;
- e) Treinamento 5 - 5 pacientes: (h) a (k);
- f) Treinamento 6 - 4 pacientes: (l).

Exemplos de sequências coronais (Figura 72) e sequências classificadas em cada treinamento:

- a) Treinamento 1 - 4 pacientes: (a);
- b) Treinamento 2 - 4 pacientes: (b) e (c);
- c) Treinamento 3 - 4 pacientes: (d);
- d) Treinamento 4 - 5 pacientes: (e);
- e) Treinamento 5 - 5 pacientes: (f) e (g);
- f) Treinamento 6 - 4 pacientes: (h) a (j).

B.4 Paciente 4

Exemplos de sequências sagitais (Figura 73) e sequências classificadas em cada treinamento:

- a) Treinamento 1 - não realizado;
- b) Treinamento 2 - não realizado;
- c) Treinamento 3 - 4 pacientes: (c) e (d);
- d) Treinamento 4 - não realizado;
- e) Treinamento 5 - 5 - pacientes: (a) e (b);

Figura 71: Paciente 4: Exemplos de cada sequência sagital (Continua).





Figura 71: Paciente 4: Exemplos de cada sequência sagital (Conclusão).



Fonte: Produção da autora, 2016.

f) Treinamento 6 - não realizado;


Para sequências coronais, não foi realizado o treinamento, uma vez que existiam apenas 2 sequências.

B.5 Paciente 6

Exemplos de sequências sagitais (Figura 74) e sequências classificadas em cada treinamento:


- a) Treinamento 1 - 4 pacientes: (p);
- b) Treinamento 2 - 3 pacientes: (d) a (g);
- c) Treinamento 3 - 4 pacientes: (a) a (c) e (h) a (j);

Figura 72: Paciente 4: Exemplos de cada sequência coronal (Continua).



Fonte: Produção da autora, 2016.


Figura 72: Paciente 4: Exemplos de cada sequência coronal (Conclusão).




(a)

Fonte: Produção da autora, 2016.


Figura 73: Paciente 5: Exemplos de cada sequência sagital.




(a)



(b)



(c)



(d)


Fonte: Produção da autora, 2016.

d) Treinamento 4 - 3 pacientes: (k) e (l);

e) Treinamento 5 - 5 pacientes: (m);


f) Treinamento 6 - 4 pacientes: (n) e (o);

Figura 74: Paciente 6: Exemplos de cada sequência sagital (Continua).



Exemplos de sequências coronais (Figura 75) e sequências classificadas em cada treinamento:


Figura 74: Paciente 6: Exemplos de cada sequência sagital (Conclusão).



Fonte: Produção da autora, 2016.

- a) Treinamento 1 - 4 pacientes: (a);
- b) Treinamento 2 - não realizado;
- c) Treinamento 3 - 4 pacientes: (b);
- d) Treinamento 4 - 5 pacientes: (c);
- e) Treinamento 5 - 5 pacientes: (d);
- f) Treinamento 6 - 4 pacientes: (e);

Figura 75: Paciente 6: Exemplos de cada sequência coronal.



Fonte: Produção da autora, 2016.