

DISSERTAÇÃO DE MESTRADO

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM
CIÊNCIA DA COMPUTAÇÃO

**“Segmentação e quantificação de tecidos da
coxa e abdômen em imagens de tomografia
computadorizada”**

**ALUNO: Jonas de Carvalho Felinto
ORIENTADOR: Prof. Dr. Ricardo José Ferrari**

**São Carlos
Abril/2018**

**CAIXA POSTAL 676
FONE/FAX: (16) 3351-8233
13565-905 - SÃO CARLOS - SP
BRASIL**

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**SEGMENTAÇÃO E QUANTIFICAÇÃO DE
TECIDOS DA COXA E ABDÔMEN EM
IMAGENS DE TOMOGRAFIA
COMPUTADORIZADA**

JONAS DE CARVALHO FELINTO

ORIENTADOR: PROF. DR. RICARDO JOSÉ FERRARI

São Carlos – SP

Abril/2018

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**SEGMENTAÇÃO E QUANTIFICAÇÃO DE
TECIDOS DA COXA E ABDÔMEN EM
IMAGENS DE TOMOGRAFIA
COMPUTADORIZADA**

JONAS DE CARVALHO FELINTO

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação, área de concentração: Processamento de Imagens e Sinais.

Orientador: Prof. Dr. Ricardo José Ferrari

São Carlos – SP

Abril/2018



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Ciência da Computação

Folha de Aprovação

Assinaturas dos membros da comissão examinadora que avaliou e aprovou a Defesa de Dissertação de Mestrado do candidato Jonas de Carvalho Felinto, realizada em 27/04/2018:

Prof. Dr. Ricardo José Ferrari
UFSCar

Prof. Dr. José Hiroki Saito
UFSCar

Prof. Dr. Marcelo Zancheta do Nascimento
UFU

Certifico que a defesa realizou-se com a participação à distância do(s) membro(s) Marcelo Zancheta do Nascimento e, depois das arguições e deliberações realizadas, o(s) participante(s) à distância está(ao) de acordo com o conteúdo do parecer da banca examinadora redigido neste relatório de defesa.

Prof. Dr. Ricardo José Ferrari

AGRADECIMENTOS

Agradeço a todos que de alguma forma contribuíram para a execução deste trabalho, em especial ao meu orientador Prof. Dr. Ricardo José Ferrari, por seus ensinamentos, conselhos e todo outro tipo de suporte que me tenha oferecido.

Agradeço também aos meus colegas de laboratório pelas construtivas discussões e observações, agradeço também ao laboratório GAPIS e ao DC-UFSCar pela estrutura disponibilizada e à CAPES pelo apoio financeiro durante minha pesquisa.

Por fim, agradeço a minha família, minha namorada Katia Poloni e minha a minha “filha” Duda por todos os momentos de felicidade e alegria que me dão forças para continuar e melhorar a cada dia.

RESUMO

A quantificação de tecidos adiposos e musculares é de grande importância na prática clínica e auxilia no diagnóstico de doenças como diabetes tipo 2, resistência insulínica e osteoartrite. O uso de imagens de tomografia computadorizada (TC) tornou-se indispensável para a quantificação de tais tecidos e, atualmente, é considerado o padrão ouro na prática clínica. O imageamento por TC é capaz de produzir resultados com alta acurácia, com grande contraste de tecidos moles, além de menor custo financeiro e ser mais rápido que a ressonância magnética. Atualmente, a quantificação de tecidos é realizada manualmente por um radiologista especializado com a ajuda limitada do computador e, portanto, possui diversas limitações. Por esse motivo, vários pesquisadores têm voltado seus esforços para o desenvolvimento de técnicas automáticas de segmentação de tecidos. Embora algumas técnicas automáticas, propostas na literatura, apresentem valores elevados de correlação entre os resultados das segmentações automáticas e das marcações manuais de especialistas, os resultados foram obtidos usando poucas imagens e, até o momento, nenhuma dessas técnicas estão disponíveis para a comunidade médica. Nesse contexto, este trabalho de pesquisa tem como objetivo a criação de uma técnica computacional que permita realizar de maneira automática a segmentação e quantificação de tecidos da coxa e abdômen em imagens de TC. Essa técnica combina operações morfológicas, limiarização, um modelo de mistura gaussiana e o uso de uma matriz acumuladora em conjunto com a projeção de linhas digitais para classificar cada voxel de gordura em relação a sua posição à outros tecidos. Posteriormente uma avaliação quantitativa foi feita usando 144 imagens de coxas extraídas de 72 exames de TC da coxa (esquerda e direita) e 15 imagens de TC do abdômen. Todas as imagens foram manualmente segmentadas por um especialista com o auxílio de um software de edição de imagens e utilizadas para posterior análise comparativa. Os resultados de precisão para a obtenção das máscaras que delimitam a coxa e a fáscia e que delimitam o abdômen e a região visceral são ambos de 0,99 e 0,98, respectivamente. Além disso, o coeficiente de similaridade de dice para essas áreas foi próximo a 0,98.

Palavras-chave: tecido adiposo visceral, tecido adiposo subcutâneo, tecido adiposo intermuscular, tomografia computadorizada, segmentação automática.

ABSTRACT

The quantification of adipose and muscular tissues is of great importance in clinical practice and assists in the diagnosis of diseases such as type 2 diabetes, insulin resistance and osteoarthritis. The use of Computed Tomography (CT) imaging has become indispensable for the quantification of such tissues and is currently considered the gold standard in clinical practice. CT imaging is able to produce results with high accuracy, with high soft tissue contrast, lower financial cost and time-wise efficiency when compared to MRI. Currently, the quantification of tissues is performed manually by a specialized radiologist with limited help of the computer and therefore has several limitations. For this reason, several researchers have turned their efforts to the development of automatic techniques of tissue segmentation. Some automatic techniques presented in the literature show high correlation values between automatic segmentation results and manual specialist markings, but the results were obtained using few images and to date none of these techniques are available to the medical community. In this context, this research aims to create a computational technique that allows automatic segmentation and quantification of thigh and abdomen tissues in CT images. This technique combines morphological operations, thresholding, a Gaussian mixture model and the use of an accumulator matrix with the projection of digital lines to classify each fat voxel in relation to its position to other tissues. Subsequently, a quantitative evaluation was done using 144 thigh images extracted from 72 thighs CT scans (left and right) and 15 CT images from the abdomen. All images were manually segmented by a specialist using image editing software and used for further comparative analysis. The precision results for the masks that delimit the thigh and fascia and that delimit the abdomen and the visceral region are 0.99 and 0.98, respectively. Also, the coefficient of similarity of dice for these areas was close to 0.98.

Keywords: visceral adipose tissue, subcutaneous adipose tissue, intermuscular adipose tissue, computed tomography, automatic segmentation.

LISTA DE FIGURAS

2.1	Ilustração da aquisição dos dados em TC. Extraído de Siemens Healthcare GmbH (2016).	20
2.2	Contornos manuais delineados pelo especialista. a) coxa; b) abdômen.	24
2.3	Imagem original com aplicação dos filtros de dilatação e erosão; e aplicação das operações de abertura de fechamento. Extraído de Gonzalez e Woods (2006).	25
2.4	Os dois quadrados verdes na parte superior da imagem original (S) exemplificam uma situação de <i>hit</i> com o elemento estruturante ao lado (F). Já o quadrado azul na parte inferior exemplifica uma situação de <i>fit</i> com o mesmo elemento estruturante (F).	26
2.5	Discretização de uma reta em uma matriz de pixels (imagem). A seta em preto simboliza a reta a ser discretizada, os pixels em verde simbolizam os que pertencem à reta discretizada e a seta em vermelho indica o vértice cortado pela reta.	28
2.6	Exemplo da classificação de um pixel utilizando três linhas digitais.	29
2.7	Procedimento de “espelhamento” das linhas digitais.	30
4.1	Visão geral do fluxograma para a segmentação das regiões de interesse da coxa e do abdômen em imagens de TC.	46
4.2	Fluxograma das etapas de pré-processamento da coxa.	47
4.3	Fluxograma das etapas de pré-processamento do abdômen.	47
4.4	a) Imagem de TC da coxa original; b) Resultado da etapa de limiarização; c) Resultado da etapa de erosão e; d) Resultado da dilatação da coxa esquerda.	48
4.5	Exemplos de imagem de TC (a) com as coxas grudadas (b) com as coxas separadas.	49

4.6	Passos para separar as coxas (a) pontos usados no processo de separação das coxas; (b) coxas separadas usando os pontos P1 e P2.	50
4.7	a) Imagem de TC do abdômen original; b) Resultado da etapa de limiarização; c) Resultado da etapa de obtenção do maior objeto e; d) Resultado da etapa de preenchimento de buracos.	51
4.8	Imagens da coxa esquerda. a) Imagem resultante da aplicação do MMFG; b) Imagem resultante da remoção da pele e pequenos objetos; c) Resultado da etapa de classificação dos voxels de acordo com sua posição. Os mapas de cores mostram os valores da matriz acumuladora.	52
4.9	Imagens do abdômen. a) Imagem resultante da aplicação do MMFG; b) Imagem resultante da remoção da pele e pequenos objetos; c) Resultado da etapa de classificação dos voxels de acordo com sua posição. Os mapas de cores mostram os valores da matriz acumuladora.	53
4.10	Máscaras binárias obtidas para a segmentação das regiões de interesse; (a) região delimitada pela fáschia na coxa e (b) região visceral no abdômen.	55
5.1	A coluna à esquerda representa as imagens originais e a coluna da direita é a representação visual do delineamento (cor verde para a coxa esquerda e azul para direita) gerado pela etapa de pré-processamento sobreposta à imagem original.	58
5.2	A coluna à esquerda representa as imagens originais e a coluna da direita é a representação visual do delineamento (cor verde) gerado pela etapa de pré-processamento sobreposta à imagem original.	60
5.3	Resultado da etapa da projeção das linhas digitais. (a) coxa usando 16 linhas digitais (2D); (b) coxa usando 80 linhas digitais (3D); (c) abdômen usando 16 linhas digitais (2D); e (d) abdômen usando 80 linhas digitais (3D). Os mapas de cores em cada imagem mostram os valores de variação do contador.	61
5.4	Avaliação do parâmetro das linhas digitais (T_l) usando as abordagem 2D e 3D para as coxas (a) e (b) e para o abdômen (c) e (d), respectivamente.	62

5.5	Resultado das delimitações obtidas pelos melhores valores de T_l . A coluna da esquerda representa as imagens originais, a coluna central representa as marcações manuais do especialista e a coluna da direita representa as segmentações obtidas automaticamente pelos melhores valores de T_l . A representação visual do delineamento é mostrada na cor verde para a coxa esquerda e azul para direita; e verde para a região visceral.	63
5.6	Imagem de TC com (a) borda da fáscia detectada utilizando o método automático (amarelo) e marcação manual produzida por um especialista (vermelho); (b) Zoom da imagem para ilustrar uma discordância entre o contorno manual e automático.	66
5.7	Análises de correlação para os tecidos da coxa calculados de forma manual e automática. (a) TAS; (b)músculo; (c) TA-Intermuscular e; (d) TA-Intramuscular.	67
5.8	Imagem de TC do abdômen (a) original; (b) borda da região visceral detectada utilizando o método automático (contorno verde); e (c) marcação manual produzida por um especialista (contorno azul).	69
5.9	Análises de correlação para os tecidos da coxa calculados de forma manual e automática. (a) TAS e; (b) TAV.	71
5.10	Resultados médios e desvio padrão (em preto) obtidos de seis marcações manuais (três especialistas com duas marcações cada um) comparado com o método automática (ponto em vermelho) para a quantificação do TA-Intermuscular. . .	72

LISTA DE TABELAS

2.1	Intervalos na escala HU referentes à absorção dos tecidos adiposos e musculares.	23
5.1	Avaliação quantitativa obtida para a comparação entre as máscaras binárias determinadas automaticamente e manualmente para a coxa na etapa de pré-processamento.	59
5.2	Avaliação quantitativa obtida da comparação entre as máscaras binárias geradas automaticamente e manualmente para o abdômen na etapa de pré-processamento.	59
5.3	Avaliação quantitativa obtida da comparação entre as máscaras binárias determinadas automaticamente e manualmente para a região delimitada pela fáscia. Os resultados das métricas são apresentados com a média \pm desvio padrão, usando todas as imagens da base de dados.	64
5.4	Avaliação quantitativa para a quantificação de todos os tecidos da coxa em imagens de TC aplicando a técnica proposta 3D.	65
5.5	Avaliação quantitativa para a quantificação de todos os tecidos da coxa em imagens de TC aplicando a técnica proposta 2D.	66
5.6	Avaliação quantitativa obtida da comparação entre as máscaras binárias determinadas automaticamente e manualmente para a região visceral. Os resultados das métricas são apresentados com a média \pm desvio padrão, usando todas as imagens da base de dados.	68
5.7	Avaliação quantitativa para a quantificação de todos os tecidos da coxa em imagens de TC aplicando a técnica proposta 2D.	69
5.8	Avaliação quantitativa para a quantificação de todos os tecidos da coxa em imagens de TC aplicando a técnica proposta 3D.	70

LISTA DE ABREVIATURAS E SIGLAS

ACM	Active contour model
AIB	Análise de impedância bioelétrica
ASM	Active shape model
DSC	Dice similarity coefficient
EM	Expectation maximization
ER	Erro relativo
FCM	Fuzzy c-mean
FFN	Fração de falso negativo
FFP	Fração de falso positivo
FN	Falso negativo
FP	Falso positivo
GVF	Gradient vector flow
HU	Hounsfield units
ILT	Inside lean tissue
IMC	Índice de massa corporal
MAP	Maximum a posteriori
MLE	Maximum likelihood estimation
MMFG	Modelo de mistura finita de gaussianas
OA	Osteoartrite

RM	Ressonância magnética
SBGFRLS	Selective binary gaussian filtered regularized level set
TA	Tecido adiposo
TA-Intermuscular	Tecido adiposo intermuscular
TA-Intramuscular	Tecido adiposo intramuscular
TAS	Tecido adiposo subcutâneo
TAV	Tecido adiposo visceral
TC	Tomografia computadorizada
VBGMM	Variational inference for the gaussian mixture model
VN	Verdadeiro negativo
VP	Verdadeiro positivo

SUMÁRIO

CAPÍTULO 1 – INTRODUÇÃO	15
1.1 Contexto e motivação	15
1.2 Objetivo	17
1.2.1 Objetivos Específicos	17
1.3 Organização do trabalho	17
CAPÍTULO 2 – FUNDAMENTAÇÃO TEÓRICA	19
2.1 Tomografia Computadorizada	19
2.1.1 Princípios físicos	20
2.2 Segmentação manual	23
2.3 Filtros morfológicos	24
2.4 Linhas Digitais	27
2.5 Modelo de Mistura Finita de Gaussianas (MMFG)	30
2.6 Metodologia de análise	32
2.6.1 DSC	33
2.6.2 ER	33
2.6.3 Precisão	33
2.6.4 Revocação	33
2.6.5 F1-score	33
2.6.6 Regressão	34

2.7	Considerações finais	35
CAPÍTULO 3 – REVISÃO BIBLIOGRÁFICA		36
3.1	Visão Geral	36
3.2	Segmentação abdômen	36
3.2.1	Trabalhos Correlatos	37
3.3	Segmentação coxa	40
3.3.1	Trabalhos Correlatos	41
3.4	Discussão	43
3.5	Considerações Finais	44
CAPÍTULO 4 – METODOLOGIA		45
4.1	Visão Geral	45
4.2	Base de Dados	46
4.3	Pré-processamento	47
4.3.1	Detecção da coxa	47
4.3.2	Detecção do abdômen	50
4.4	Método para o processamento das imagens de TC	52
4.5	Pós-processamento	54
4.5.1	Segmentação das regiões de interesse	54
4.6	Forma de análise dos resultados	55
4.7	Considerações finais	56
CAPÍTULO 5 – RESULTADOS E DISCUSSÕES		57
5.1	Visão geral	57
5.2	Pré-processamento	57
5.2.1	Detecção da coxa	58
5.2.2	Detecção do abdômen	59

5.3	Segmentação das regiões de interesse	60
5.3.1	Linhas digitais	60
5.3.2	Região delimitada pela fáscia	64
5.3.2.1	Quantificação dos tecidos da coxa	65
5.3.3	Região visceral	67
5.3.3.1	Quantificação dos tecidos do abdômen	68
5.4	Variabilidade entre os especialistas	71
5.5	Considerações Finais	72
CAPÍTULO 6 – CONCLUSÕES		74
6.1	Conclusões	74
6.2	Principais contribuições	75
6.3	Sugestões para trabalhos futuros	75
REFERÊNCIAS BIBLIOGRÁFICAS		77

Capítulo 1

INTRODUÇÃO

Este capítulo apresenta o contexto no qual esta pesquisa está inserida, explicando o problema a ser investigado e as motivações para resolvê-lo, além de servir como introdução ao conteúdo apresentado nos próximos capítulos.

1.1 Contexto e motivação

O tecido adiposo (TA), por ser capaz de se expandir ao longo da vida, é considerado o maior órgão endócrino do corpo humano (STEHNO-BITTEL, 2008) e não apenas um depósito de armazenamento para o excesso de calorias. A distribuição dos tecidos adiposos e musculares no corpo são de central importância para o metabolismo humano e em estudos patológicos (FISHBEIN et al., 2006; GOODPASTER et al., 1997), os quais têm mostrado que mudanças na composição do corpo, como o acúmulo de tecido adiposo ou redução de massa magra, possuem um efeito cumulativo com o envelhecimento e doenças crônicas e mediam seu impacto na função física (FERRUCCI; STUDENSKI, 2009).

O aumento da massa adiposa está diretamente relacionado ao consumo, em excesso, de ácidos graxos saturados, os quais são responsáveis pela condição sistêmica de inflamação de baixo grau e resistência à insulina e à leptina (SARTORI-CINTRA; AIKAWA; CINTRA, 2014). Os principais tecidos adiposos cujos acúmulos estão relacionados a doenças são o visceral (TAV) e o intermuscular (TA-Intermuscular), que são encontrados em conjunto com o subcutâneo (TAS) e o intramuscular (TA-Intramuscular).

No abdômen o acúmulo do TAS e do TAV estão relacionados à obesidade visceral (CHAN et al., 1994), doenças cardíacas (SHIMOMURA et al., 1996; ORGANIZATION. et al., 1999), resistência insulínica (CHAN et al., 1994), diabetes tipo 2, síndrome metabólica (GAMI et al.,

2007) e a doenças relacionadas ao acúmulo de placas nas paredes da artéria (OHSHIMA et al., 2008). Por outro lado, na coxa o acúmulo do TAS, TA-Intramuscular e TA-Intermuscular estão relacionados à perda da função de mobilidade (GOODPASTER et al., 2008; ADDISON et al., 2014) e força (YOSHIDA; MARCUS; LASTAYO, 2012; MANINI et al., 2007), resistência insulínica (GOODPASTER; THAETE; KELLEY, 2000; GOODPASTER et al., 2003; YIM et al., 2007) e aumento das chances do desenvolvimento de diabetes tipo 2 (ADDISON et al., 2014).

O acúmulo excessivo de tecidos adiposos no corpo é chamado de obesidade. Ela pode ser causada por fatores genéticos e anormalidades metabólicas, como hipotireoidismo, comida em excesso, falta de exercício físico e estresse, além de ser um dos principais fatores em doenças crônicas. A obesidade vai além do sobrepeso e, embora existam diversos tipos de obesidade causadas por diferentes distribuições de gordura pelo corpo, a obesidade abdominal foi relatada pela Organização Mundial da Saúde¹ como uma das que apresentam maior risco (GARROUSTE-ORGEAS et al., 2004; ST-PIERRE et al., 2002). A projeção é de que em 2025 cerca de 2,3 bilhões de adultos tenham sobrepeso² e mais de 700 milhões sejam obesos. No Brasil, o crescimento também é ascendente, sendo que atualmente 50% da população é formada por indivíduos com sobrepeso ou obesos.

Em geral, a quantificação de tecidos é realizada utilizando imagens de tomografia computadorizada (TC) ou ressonância magnética (RM). Embora o imageamento por RM apresente maior contraste entre os tecidos adiposos do que a TC (KARAMPINOS et al., 2012; CHEEMA et al., 2010; WATTJES; KLEY; FISCHER, 2010), o exame de TC é mais rápido, possui menor custo financeiro e é considerado o padrão ouro na prática clínica devido à sua alta acurácia (KIM et al., 2016). O exame de TC possui um coeficiente de atenuação, que é uma medida arbitrária criada por *Hounsfield* (HU) (YOSHIZUMI et al., 1999) para quantificar a atenuação de feixes de raios X, após estes atravessarem o corpo. Portanto, nesse exame, a representação de cada tecido é feita na escala de HU e varia de acordo com a sua absorção de fótons de raios X, permitindo assim, uma avaliação quantitativa e padronizada dos tecidos (YOSHIZUMI et al., 1999). Neste caso, a absorção da água corresponde ao valor zero da escala.

Atualmente, a segmentação de estruturas anatômicas em imagens de TC para a medição das quantidades de cada tecido é realizada de maneira semimanual com o auxílio de programas de edição de imagens (KIM et al., 2016), os quais, em geral, possuem o recurso de janelas de intensidade pré-definidas para alguns tecidos na escala HU (YOSHIZUMI et al., 1999). Entre-

¹<http://www.abeso.org.br/atitude-saudavel/mapa-obesidade>

²Um indivíduo tem sobrepeso quando o seu índice de massa corporal (IMC) está entre 25 e 29,9 e é considerado obeso quando seu IMC for maior que 30.

tanto, a análise semimanual, além de ser um processo demorado e de alto custo financeiro, é bastante sensível a variações inter e intraobservadores. Neste contexto, métodos automatizados para a segmentação e quantificação de tecidos em imagens de TC são de amplo interesse clínico (POSITANO et al., 2009).

1.2 Objetivo

Com base nos relatos anteriores, o principal objetivo deste trabalho de pesquisa foi desenvolver uma técnica computacional automática para a segmentação e quantificação de tecidos da coxa e abdômen em imagens de TC.

1.2.1 Objetivos Específicos

Adicionalmente, os seguintes objetivos específicos foram estabelecidos para possibilitar o desenvolvimento desta pesquisa:

- Pré-processar as imagens para a obtenção das máscaras que delimitam a coxa e o abdômen.
- Segmentar as regiões visceral (abdômen) e delimitada pela fáscia (coxa) utilizando a técnica de linhas digitais.
- Quantificar os tecidos adiposos e musculares utilizando limiarizações em HU.
- Validar o método utilizando as marcações manuais de especialistas (*ground-truth*).
- Avaliar a eficácia do método utilizando métricas estatísticas.

1.3 Organização do trabalho

Este trabalho está dividido em seis capítulos:

- Capítulo 1: São abordadas as informações que buscam contextualizar o leitor no problema a ser investigado, dando motivação à pesquisa.
- Capítulo 2: Contém informações sobre a formação das imagens de TC e também informações teóricas sobre as técnicas usadas nesta pesquisa.

-
- Capítulo 3: Contém a revisão bibliográfica relacionada às técnicas de segmentação de imagens de TC e RM do abdômen e da coxa.
 - Capítulo 4: Apresenta os materiais e métodos utilizados e desenvolvidos nesta pesquisa.
 - Capítulo 5: Contém a apresentação e discussão dos resultados obtidos.
 - Capítulo 6: Contém as conclusões, contribuições e ideias para trabalhos futuros.

Capítulo 2

FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta informações complementares sobre o processo de formação e aquisição das imagens de tomografia computadorizada relevantes para o entendimento desta pesquisa. Contém também informações e conceitos teóricos sobre as técnicas utilizadas nesta pesquisa.

2.1 Tomografia Computadorizada

A tomografia computadorizada (TC) é uma modalidade da radiologia reconhecida por seu alto potencial de diagnósticos. A técnica foi desenvolvida em 1972 por Godfrey Hounsfield (HOUNSFIELD, 1980) e Cormak (CORMACK, 1980), o que fez com que os dois pesquisadores ganhassem o Prêmio Nobel em Medicina e Fisiologia em 1979 (HENDEE; RITENOUR; HOFFMANN, 1992). A TC possibilitou investigar detalhes anatômicos do corpo humano via imagens 3D que não era possível até aquele momento.

A TC é um dos métodos de diagnóstico por imagem que utiliza radiação ionizante produzida artificialmente para gerar imagens do interior de objetos em forma de cortes (FELIX, 2012). Suas imagens são produzidas com maior nível de detalhamento que os exames convencionais de raios X (HENDEE; RITENOUR; HOFFMANN, 1992), e são mais indicadas, principalmente, quando há necessidade de visualização de vasos sanguíneos e tecidos moles, como o músculo e gorduras (CARLOS, 2002).

Desde a criação, os tomógrafos passaram por uma grande evolução. No início, a aquisição dos dados era realizada corte a corte, conhecida como varredura axial, e exigia que o paciente fosse submetido à altas taxas de radiação. Em 1985, a velocidade de aquisição dos dados teve um aumento significativo com o surgimento da varredura helicoidal, que fazia a aquisição dos

dados de maneira volumétrica, além de permitir uma menor exposição do paciente à radiação ionizante (BUSHBERG, 2002).

2.1.1 Princípios físicos

Em termos gerais, a imagem de TC consiste de um processo de representação de um corpo tridimensional por meio de cortes bidimensionais em uma dada direção usando um mapeamento linear de atenuação em uma seção do corpo humano. Neste caso, a imagem é representada por uma matriz bidimensional, em que cada elemento possui um valor de intensidade atrelado a ele, representado em unidades de Hounsfield (HU) (CARLOS, 2002).

Um equipamento de TC é composto pelas seguintes partes: *gantry* (responsável pela aquisição dos dados), mesa de acomodação do usuário, mesa de comando e um computador responsável pelo processamento dos comandos. A formação de uma imagem de TC é dividida em três etapas: aquisição dos dados, reconstrução matemática e formatação, e apresentação. A Figura 2.1 ilustra um exemplo de aquisição de dados, em que moldura circular refere-se ao *gantry*, que é composto por um tubo de raios X e detectores. A aquisição dos dados refere-se ao tipo de sistema de coleta das informações do paciente. Existem dois principais métodos: a aquisição de dados *slice-by-slice* (varredura axial) e a aquisição de dados por volume (varredura helicoidal) (BUSHBERG, 2002).

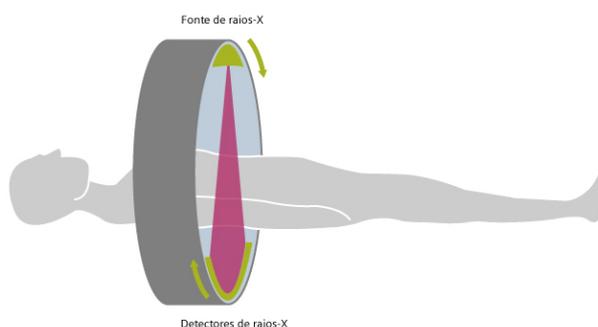


Figura 2.1: Ilustração da aquisição dos dados em TC. Extraído de Siemens Healthcare GmbH (2016).

Na varredura axial os dados são coletados pelo movimento do tubo de raios X e dos detectores utilizando uma única rotação em torno do paciente. Ao terminar a varredura da área, a movimentação cessa e a mesa movimenta o paciente para uma nova região a ser irradiada, até que todos os *slices* desejados tenham sido adquiridos. Na varredura helicoidal, uma parte do corpo do paciente é exposta a um feixe de raios X no formato de um leque fino e um detector de fótons que gira ao redor do corpo do paciente como uma hélice. Conforme ocorrem as ro-

tações, inúmeras imagens do corpo do paciente são tiradas; neste tipo de aquisição, a mesa se move continuamente até que todas as imagens da região anatômica desejada sejam adquiridas (CARLOS, 2002).

Para melhor entendimento da aquisição, alguns conceitos serão explicados. Na varredura, durante o movimento do tubo de raios X e detectores, são emitidos raios paralelos com uma intensidade e um ângulo ao redor do corpo em uma direção fixa para que os detectores façam a leitura do sinal. Tais raios são colimados para que seu espalhamento seja reduzido e o tamanho do campo de incidência dos raios X limitado. Quando um raio atravessa o corpo do paciente, ele é atenuado - uma parte dos fótons é absorvida, uma parte é espalhada e outra parte é transmitida, passando pelo corpo e chegando até os detectores. Portanto, no momento em que os detectores forem fazer a leitura do sinal, e será proporcional ao grau de atenuação (BUSHBERG, 2002). A cada rotação do tubo com diferentes angulações é obtido um conjunto de perfis de atenuação, o qual é composto por perfis de atenuação ou transmissão relativa (TR), que é definida por:

$$TR = \frac{\text{intensidade dos raios da fonte}}{\text{intensidade dos raios nos detectores}}, \quad (2.1)$$

cujos valores são enviados para o computador e armazenados em dados brutos.

Existem também dois possíveis tipos de feixe de radiação, homogêneo e heterogêneo. No primeiro, todos os fótons possuem a mesma energia e no segundo, os fótons possuem energias diferentes. Em sua primeira tentativa de desenvolvimento do feixe, Hounsfield utilizou um feixe homogêneo com uma fonte de radiação gama, pelo fato de tal fonte satisfazer a lei de *Beer-Lambert*, definida por:

$$I = I_0 \cdot e^{-\mu \cdot x}, \quad (2.2)$$

em que I corresponde à intensidade transmitida (feixe atenuado), I_0 a intensidade original, x a espessura do objeto, e é constante de *Euler* e μ refere-se ao coeficiente de atenuação linear em cm^{-1} (HENDEE; RITENOUR; HOFFMANN, 1992). Como tratam-se de feixes homogêneos, bastava apenas resolver a equação 2.2 para encontrar o valor de μ . Porém ao iniciar seus experimentos, Hounsfield verificou que os os fótons da fonte gama tinham baixa intensidade e então precisou substituir a fonte gama por um tubo de raios X (SEERAM, 2015).

Devido a equação de *Beer-Lambert* ser diretamente aplicável somente para feixes homogêneos, Housfield propôs aproximações do espalhamento e absorção da radiação para adaptá-la. Isso foi possível devido aos raios X poderem ser atenuados por meio do efeito fotoelétrico e espalhados pelo efeito Compton, fazendo com que o coeficiente de atenuação (μ) pudesse ser representado por $\mu_p + \mu_c$. O efeito fotoelétrico é dependente da energia do feixe e ocorre principalmente em tecidos com alto número atômico, como o osso; e o efeito Compton ocorre

em tecidos moles, cujas diferenças de densidade resultam em diferentes interações Compton. Porém, mesmo com as adaptações, a equação 2.2 ainda não podia ser aplicada para feixes heterogêneos. Housfield propôs então deixar de utilizar as intensidades (I) e utilizar a quantidade de fótons (N), uma vez que com feixes heterogêneos há uma variação na quantidade de fótons ao longo do feixe. A nova fórmula foi definida como:

$$N = N_0 \cdot e^{-(\mu_p + \mu_c) \cdot x}, \quad (2.3)$$

em que N representa o número de fótons que atravessam o tecido durante a aquisição dos dados (SEERAM, 2015).

Na segunda etapa a reconstrução é realizada pelo computador utilizando métodos matemáticos que transformam os dados obtidos acima em uma imagem digital. O objetivo da reconstrução é estimar como as absorções dos tecidos são distribuídas ao longo dos raios X (NEWTON, 2016). Embora existam métodos matemáticos para a reconstrução de imagens de TC, como a retroprojeção filtrada, reconstrução algébrica e projeções em conjuntos convexos, o método da retroprojeção filtrada é o mais utilizado (CARLOS, 2002); ele propõe a reconstrução da imagem usando filtragem e convolução, a fim de reduzir a degradação sofrida pela reconstrução usando um número finito de projeções (SALVADEO, 2013). A imagem final é, então, armazenada na memória ou em disco.

Na tomografia uma imagem digital é descrita por uma matriz bidimensional, em que cada elemento (pixel) possui um valor numérico denominado número de TC (nTC), medido em HU, o qual está relacionado ao coeficiente linear médio de atenuação do elemento do objeto que ele representa; e ele é definido com base da atenuação da água:

$$nTC = \left(\frac{\mu_{\text{tecido}} - \mu_{\text{agua}}}{\mu_{\text{agua}}} \right) \times K, \quad (2.4)$$

o que faz com que a mesma tenha nTC igual a zero. Na fórmula, K é um fator de escala, o qual foi fixado como $K = 1000$ pois com tal valor, o nTC corresponde a 0,1 da escala total, aproximando-o das variações mais comuns de atenuação dos tecidos do corpo, além de corresponder à escala de HU (HAAGA; BOLL, 2008).

A escala de HU possui valores que variam entre -1000 e 3095, em que -1000 HU corresponde a atenuação do ar, a faixa entre -100 e +100 HU refere-se aos tecidos moles, como tecidos adiposos e musculares, e valores maiores que 3000 HU correspondem aos ossos densos (NEWTON, 2016; HENDEE; RITENOUR; HOFFMANN, 1992).

A terceira etapa envolve a apresentação da imagem, em que uma imagem numérica é con-

vertida para um mapa de cores para que ela possa ser visualizada e o observador consiga entender as diferenças entre tecidos. Em imagens médicas, em geral, são utilizados tons de cinza ao invés de mapas de cores. Esta fase é produzida por componentes eletrônicos que funcionam como um conversor de sinal. Os valores que relacionam um nTC com tons de cinza são estabelecidos por uma janela, na qual seus limites inferior e superior irão definir os limites dos nTC 's. Neste caso, números que estiverem acima do limite superior são mostrados na cor branca e os abaixo, na cor preta (CARLOS, 2002).

2.2 Segmentação manual

Neste trabalho a segmentação manual das regiões de interesse nas imagens de TC da coxa e abdômen foram realizadas por um especialista com o auxílio do software ITK-SNAP¹. Todas as marcações foram salvas em disco e usadas para quantificar os diferentes tecidos usando intervalos pré-definidos na escala de HU, como indicado na Tabela 2.1.

Tipos de Tecido	escala HU
TAS e TA-Intermuscular	-190 a -30
Muscular	30 a 100
TA-Intramuscular	0 a 29

Tabela 2.1: Intervalos na escala HU referentes à absorção dos tecidos adiposos e musculares.

Para a avaliação da técnica desenvolvida nesta pesquisa para a segmentação de tecidos nas imagens de TC (coxa e abdômen), somente uma das fatias da imagem, como mostram as Figuras 2.2, foi anotada pelo especialista. A Figura 2.2a apresenta um exemplo das marcações realizadas para a coxa (vermelho), região delimitada pela fáscia (amarelo) e região do osso (verde) e na Figura 2.2b tem-se o delineamento do abdômen (vermelho) e o da região visceral (amarelo).

Uma importante observação a ser feita é que os tecidos musculares possuem valores de intensidade muito semelhante aos valores das vísceras (Figura 2.2b), portanto não é possível quantificar esses tecidos com esse tipo de demarcação. Uma segunda possibilidade seria fazer essa marcação usando como base a parte interna dos músculos e não a parte externa, como indicado na Figura. Porém, por ser capaz de quantificar o TAS e TAV com maior facilidade e boa precisão, uma grande porção dos trabalhos da literatura utilizam essa demarcação (externa).

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

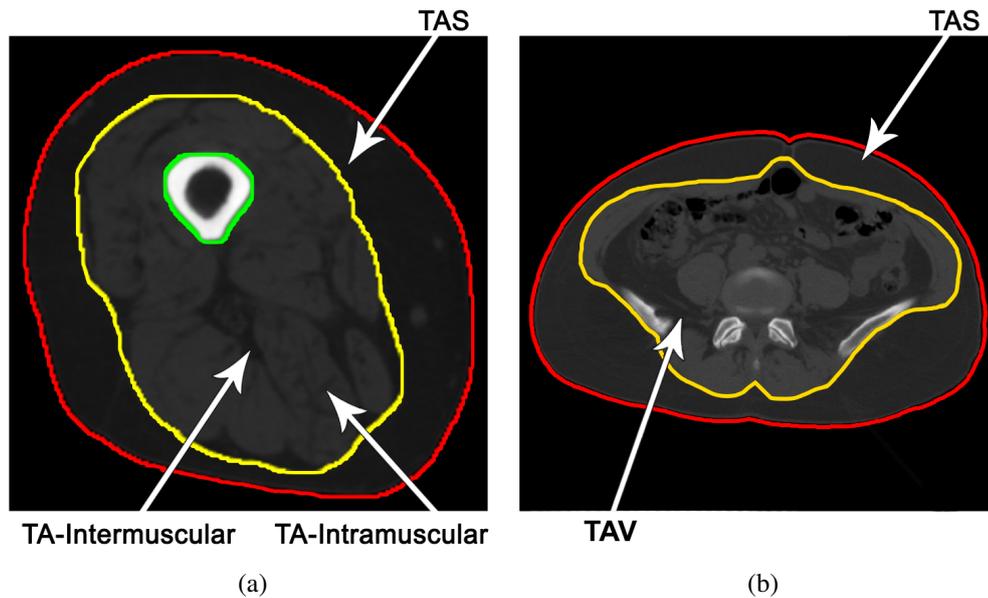


Figura 2.2: Contornos manuais delineados pelo especialista. a) coxa; b) abdômen.

2.3 Filtros morfológicos

A morfologia matemática tem como objetivo descrever ou analisar a forma de um objeto digital. Ela é uma ferramenta utilizada para extrair os componentes de uma imagem, os quais são úteis para a representação e descrição da forma de um objeto ou região. O princípio da morfologia digital é embasado no fato de que uma imagem é representada por um conjunto de pontos (pixels ou voxels) que formam subconjuntos elementares, e esses subconjuntos formam a estrutura da forma da imagem (DOUGHERTY; LOTUFO, 2003; GONZALEZ; WOODS, 2006).

A análise das imagens é realizada por um modelo morfológico que extrai informações a partir de transformações morfológicas, utilizando conceitos da teoria dos conjuntos e de álgebra *booleana* (DOUGHERTY; LOTUFO, 2003). A morfologia digital possui duas operações básicas: a erosão e dilatação, as quais utilizam um elemento estruturante. Os elementos estruturantes podem possuir qualquer tamanho e forma, porém, ao trabalhar com imagens, em geral, os elementos estruturantes são arranjos matriciais retangulares preenchidos com 0 ou 1 e com origem no centro (GONZALEZ; WOODS, 2006) da matriz.

Com essas duas operações básicas, erosão (\ominus) e dilatação (\oplus), é possível criar outras operações, como fechamento e abertura, que serão definidas a seguir. O objetivo primitivo da erosão

é diminuir o tamanho do objeto, fazendo com que objetos menores do que o elemento estruturante sejam eliminados e, dependendo do caso, o objeto pode se dividir em vários outros após a aplicação do filtro, fazendo com que o número de componentes na imagem aumente. Por outro lado, o objetivo primitivo da dilatação é aumentar o tamanho do objeto; durante a aplicação do filtro são preenchidos todos os “buracos” que forem menores que o elemento estruturante, fazendo com que objetos próximos possam se conectar e diminuindo, assim, o número de componentes na imagem. As Figuras 2.3b e 2.3c ilustram um exemplo da aplicação dos filtros de dilatação e erosão.

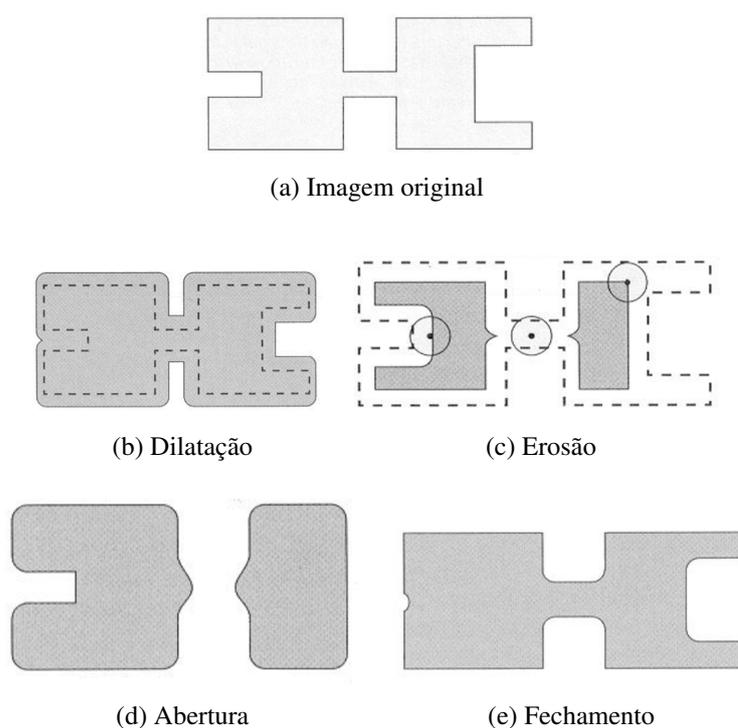


Figura 2.3: Imagem original com aplicação dos filtros de dilatação e erosão; e aplicação das operações de abertura e fechamento. Extraído de Gonzalez e Woods (2006).

Dois conceitos importantes são necessários para melhor entendimento do funcionamento dos filtros morfológicos, são eles: *fit* e *hit*. Considerando-se uma imagem binária S na qual cada pixel pode possuir somente os valores 0 ou 1, e um arranjo matricial do elemento estruturante F com valores 0 e 1, o *fit* ocorre quando **todos** os pixels do arranjo matricial com valor 1 sobrepõem-se com uma área na imagem que também contém valores 1 e o *hit* ocorre quando **qualquer** pixel do elemento estruturante com valor 1 se sobrepõe a um pixel da imagem também com valor 1. A Figura 2.4 exemplifica situações de *fit* e *hit*.

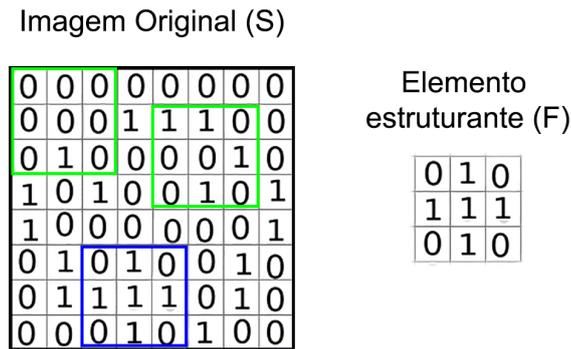


Figura 2.4: Os dois quadrados verdes na parte superior da imagem original (S) exemplificam uma situação de *hit* com o elemento estruturante ao lado (F). Já o quadrado azul na parte inferior exemplifica uma situação de *fit* com o mesmo elemento estruturante (F).

A partir dos conceitos de *fit* e *hit*, a erosão e a dilatação podem ser definidas como:

Erosão : (2.5)

$$g(x,y) = \left\{ \begin{array}{l} 1, \text{ se } S \text{ fit } F \\ 0, \text{ caso contrário} \end{array} \right\},$$

Dilatação : (2.6)

$$g(x,y) = \left\{ \begin{array}{l} 1, \text{ se } S \text{ hit } F \\ 0, \text{ caso contrário} \end{array} \right\}.$$

Utilizando os conceitos de erosão e dilatação é possível também criar outras operações, como fechamento e abertura. A operação de fechamento é uma combinação de uma operação de dilatação seguida de uma operação de erosão ($F \bullet S = (F \oplus S) \ominus S$). A operação é utilizada para eliminar pequenos buracos e preenchimento de fendas em um contorno. Já a operação de abertura é uma combinação de erosão seguida de dilatação ($F \circ S = (F \ominus S) \oplus S$), ela geralmente cria um espaço entre objetos próximos e é utilizada para remover ruídos ou pequenos artefatos, uma vez que os pontos isolados ou objetos menores que o elemento estruturante são removidos pela erosão e, na sequência, os objetos recuperam a sua forma pela operação de dilatação. As Figuras 2.3d e 2.3e ilustram um exemplo da aplicação das operações de abertura de fechamento.

2.4 Linhas Digitais

Uma linha reta em um plano cartesiano 2D é definida pela equação geral $ax + by + c = 0$, em que os parâmetros a , b e c são valores reais constantes com a e b diferentes de zero. A partir da equação geral, é possível obter a equação reduzida:

$$y = mx + n, \quad (2.7)$$

em que:

$$m = -a/b,$$
$$n = -c/b,$$

m é o coeficiente angular da reta, e corresponde à tangente do ângulo de inclinação; n é o coeficiente linear da reta, e representa o ponto em que a reta corta o eixo y . A partir dos valores de m e n é possível traçar uma reta e saber quais pontos pertencem a ela (MACHADO, 2012).

Uma imagem 2D é uma representação discreta de uma cena e, portanto, para que seja possível construir uma linha digital usando uma equação analítica da reta e determinar quais pixels pertencem a ela, é necessário que a reta seja discretizada. Uma linha digital é composta por uma sequência de pontos discretos que obedecem a uma regra de linearidade (KLETTE; ROSENFELD, 2004).

Para discretizar uma reta em uma imagem, o processo padrão é produzido utilizando uma conexão em uma vizinhança de 4 pixels, de acordo a definição: Uma linha padrão, com os parâmetros $(a, b, c) \in \mathbb{R}^3$, é um conjunto de pontos $(x, y) \in \mathbb{Z}^2$, chamados de pontos discretizados, se $-\omega \leq ax + by + c < \omega$, em que $\omega = \frac{|a|+|b|}{2}$ e $a > 0$ ou $a = 0$ e $b > 0$ (ŽUNIC, 2006). Ou seja, uma linha digital padrão, contém todos os pixels que são cortados pela reta, com exceção do caso em que a mesma corta um vértice; conforme ilustrado na Figura 2.5 - a seta vermelha indica o vértice “cortado”. Neste caso, pelo menos um dos pixels que compartilham o vértice não podem pertencer a reta.

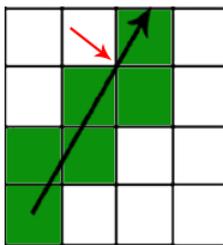


Figura 2.5: Discretização de uma reta em uma matriz de pixels (imagem). A seta em preto simboliza a reta a ser discretizada, os pixels em verde simbolizam os que pertencem à reta discretizada e a seta em vermelho indica o vértice cortado pela reta.

Nesta pesquisa, as linhas digitais são utilizadas para determinar a localização relativa de um dado pixel em uma imagem previamente segmentada em três classes; tecido adiposo, tecido não adiposo e fundo da imagem. Neste caso, para cada pixel $P(x,y)$ classificado como gordura, N linhas digitais, partindo da posição (x,y) , são escaneadas no sentido anti-horário, sendo que cada linha i possui orientação dada por $(2\pi i/N)$. O escaneamento é feito com o objetivo de atribuir um contador para cada pixel, como ilustrado na Figura 2.6. Se o escaneamento para a i -ésima direção atingir um pixel de intensidade *verde* (fundo da imagem), então o escaneamento termina para aquela direção e o contador será incrementado em uma unidade, porém, se atingir um pixel de intensidade *vermelha*, então o escaneamento termina para aquela direção e nenhum valor será atribuído ao contador.

No final do escaneamento de todas as retas, o valor máximo que o contador poderá alcançar é N , o que irá ocorrer se todas as N retas, partindo de um dado pixel $P(x,y)$, atingirem primeiro um pixel de intensidade *verde*. Por outro lado, o mínimo valor que o contador poderá alcançar é 0, que é o caso de todas as N retas saindo do pixel $P(x,y)$ atingirem primeiro um pixel de intensidade *vermelha*.

O objetivo da utilização de linhas digitais é classificar um pixel com base na probabilidade dele pertencer à máscara da região de interesse, que para o abdômen corresponde à região visceral e para a coxa à região que é delimitada pela fásia. Por exemplo, se um pixel não tem linhas em contato com o fundo da imagem é provável que ele esteja no meio dos músculos ou vísceras, logo, ele deve pertencer à região de interesse. Por outro lado, se um pixel possuir várias linhas digitais em contato com o fundo da imagem é mais provável que ele seja um pixel de gordura subcutânea do que de gordura visceral e, portanto, este pixel deve ser descartado da região de interesse.

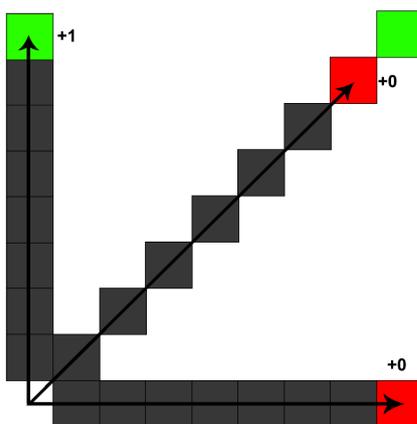


Figura 2.6: Exemplo da classificação de um pixel utilizando três linhas digitais.

Neste trabalho, as linhas digitais foram projetadas tanto para duas quanto para três dimensões (2D e 3D) para efeito de comparação. Para as projeções em 2D, 16 linhas digitais espaçadas com $22,5^\circ$ de angulação no intervalo de $[0^\circ; 360^\circ]$, foram projetadas. Para o caso 3D, 80 linhas digitais foram projetadas partindo do mesmo ponto referencial que 2D. Neste caso, foram utilizados ângulo de azimute de $22,5^\circ$ no intervalo de $[0^\circ; 360^\circ]$ (mesma angulação que em 2D) e ângulo de elevação de 30° no intervalo de $[-60^\circ; 60^\circ]$, totalizando 5 elevações. Ou seja, a mesma quantidade de linhas projetadas em 2D (16 linhas) foram projetadas para a terceira dimensão 5 vezes, totalizando assim, 80 linhas projetadas.

Para o processamento 2D, todas as 16 linhas digitais foram projetadas até que um pixel de gordura ou fundo da imagem fosse encontrado. No entanto, para o caso 3D, uma limitação ocorre devido ao reduzido número de fatias das imagens de TC da coxa e do abdômen na terceira dimensão. Vale ressaltar que, nesta pesquisa, as imagens possuem tamanho de $512 \times 512 \times 10$ voxels. Sendo assim, uma imagem com poucas fatias, limita às projeções das linhas digitais no eixo z , as quais são analisadas até que um voxel de gordura ou fundo da imagem seja encontrado nesse eixo. Portanto, para contornar a limitação, uma estratégia de espelhamento do eixo z que objetiva simular mais fatias foi criada. Tais fatias simuladas seguem o mesmo padrão das fatias já existentes. Assim, quando uma linha digital projetada no eixo z atinge o limite da imagem, ela é rebatida com a mesma angulação, conforme ilustra o desenho da Figura 2.7. Dessa forma, é possível utilizar a técnica 3D em imagens de TC com poucas fatias; e para imagens que não possuem essa limitação, esse procedimento pode ser ignorado.

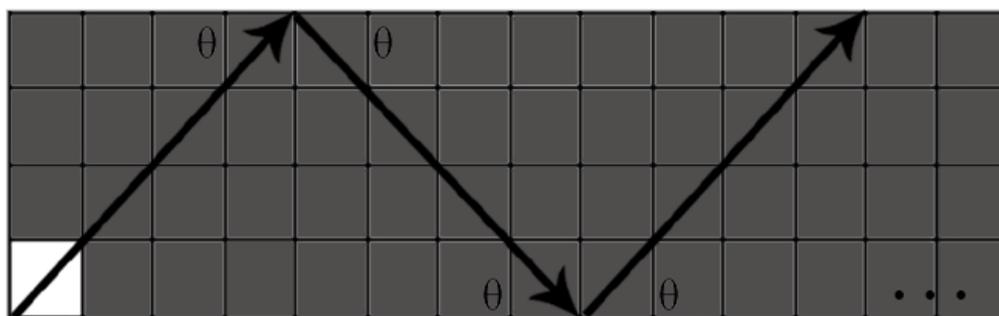


Figura 2.7: Procedimento de “espelhamento” das linhas digitais.

2.5 Modelo de Mistura Finita de Gaussianas (MMFG)

Conforme indicado na Tabela 2.1, alguns tecidos nas imagens de TC podem ser reconhecidos por valores pré-definidos nas escalas de HU, porém, dependendo de sua proximidade com outros tecidos, os raios X podem ser atenuados com maior ou menor intensidade, causando uma diferença na distribuição dos níveis de cinza dos tecidos, os quais seguem uma função massa de probabilidade (fmp). Sendo assim, para automatizar o processo de segmentação dos tecidos, tornando-o mais robusto a possíveis variações nas distribuições de probabilidade dos níveis de cinza, neste trabalho optou-se pelo uso do modelo de mistura finita de gaussianas (MMFG), por ser amplamente utilizado em problemas de segmentação de imagens médicas (NGUYEN; WU, 2012) para a determinação dos limiares de segmentação.

Um modelo de mistura é um modelo estatístico usado para representar subpopulações (TITTERINGTON; SMITH; MAKOV, 1985). Tecidos diferentes, como gordura, osso e músculos, podem ser considerados como subpopulações em uma imagem de TC da coxa ou do abdômen. Uma maneira de distinguir entre as diferentes classes é utilizando a intensidades dos voxels (FREIRE; FERRARI, 2016). Em um MMFG, subpopulações são estatisticamente descritas pelos parâmetros de uma gaussiana, ou seja, pelo vetor de médias e matriz de covariância. Porém, neste trabalho, o MMFG foi utilizado para representar distribuições de probabilidades unidimensionais, visto que o vetor de características x é composto apenas pelo nível de cinza dos voxels na imagem.

No MMFG, assume-se que distribuição dos níveis de cinza das imagens pode ser aproximada por uma soma finita e ponderada de funções gaussianas. Assume-se ainda que a quantidade de classes seja conhecida, o que, neste caso, corresponde ao número dos principais tecidos

presente nas imagens de TC. Cabe ressaltar que, em alguns casos, um dado tecido pode ser representado por uma ou mais funções gaussianas. No entanto, nesta pesquisa a relação é de 1 para 1, ou seja, uma gaussiana por tecido.

Uma vez definido o modelo de mistura, o problema passa a ser a estimação dos parâmetros das gaussianas (médias e desvios padrão), além das ponderações (pesos) de cada núcleo gaussiano. Formalmente, um modelo de mistura gaussianas é descrito da seguinte forma:

$$p(x | \Theta) = \sum_{j=1}^k \omega_j p(x | \theta_j), \quad (2.8)$$

em que $p(x | \theta_j)$ indica a densidade condicional de x na classe j dada por

$$p(x | \theta_j) = \frac{1}{\sigma_j \sqrt{2\pi}} \exp \left[-\frac{1}{2} \left(\frac{x - \mu_j}{\sigma_j} \right)^2 \right], \quad (2.9)$$

em que $\theta_j = (\mu_j, \sigma_j)$, representa o conjunto de parâmetros da j -ésima distribuição de probabilidade, com valor de média μ_j e desvio padrão σ_j . Na Equação 2.8, os valores de ω_j correspondem as ponderações das gaussianas, com $\sum_{j=1}^k \omega_j = 1$. Logo, o conjunto completo de parâmetros do MMFG é representado por $\Theta \equiv \{\omega_1, \dots, \omega_j, \theta_1, \dots, \theta_j\}$.

A estimação dos parâmetros de MMFG é comumente realizada pelo algoritmo Maximização da Esperança (*Expectation Maximization* - EM), que é um processo iterativo para computar a estimativa por máxima verossimilhança (*Maximum Likelihood Estimation* - MLE) na presença de dados não observáveis (DUDA; HART; STORK, 2012; BISHOP, 2006). Resumidamente, a execução do algoritmo EM ocorre em dois passos: (i) determinação da probabilidade das amostras x pertencerem a uma das possíveis classes; e (ii) maximização da função de verossimilhança supondo-se que os dados não observáveis sejam conhecidos (FREIRE; FERRARI, 2016).

Neste trabalho, os valores da Tabela 2.1 são usadas para determinar o número de classes existentes e também para inicializar os parâmetros do MMFG. A ponderação de cada gaussiana no MMFG é determinada a partir da contagem (\sum_{tecido}) da ocorrência de cada tecido e posteriormente dividindo \sum_{tecido} pela quantidade de voxels da região de interesse ($\sum_{\text{tecido}} / \sum_{\text{total}}$). Esses valores também são obtidos da Tabela 2.1.

Finalmente, após a estimação dos parâmetros do MMFG, é feito o mapeamento probabilístico entre as intensidades dos voxels da imagem x com o conjunto de rótulos z , dessa forma, voxels com intensidades semelhantes serão mapeados para um mesmo rótulo (DUDA; HART; STORK, 2012). Essa classificação usa a regra de decisão Bayesiana de máxima a posteriori

(*Maximum a posteriori* - MAP) de acordo com:

$$P(z_i|x) = \frac{p(x | \theta_i)P(z_i)}{p(x)} \underset{z_j}{\geq} P(z_j|x) = \frac{p(x | \theta_j)P(z_j)}{p(x)}, \quad (2.10)$$

em que $i = 1, 2, \dots, K$, $j = 1, 2, \dots, K$ e $i \neq j$. Ou seja, o processo de classificação implica em associar a cada voxel um rótulo de classe cuja probabilidade *a posteriori* é máxima. O MMFG e a decisão MAP são usados na etapa de processamento para separar a gordura dos outros tipos de tecidos.

2.6 Metodologia de análise

O valor *Dice* (DSC) é uma medida simples e útil para o cálculo de sobreposição espacial entre dois objetos, que pode ser aplicada a estudos de reprodutibilidade e precisão na segmentação de imagens (ZOU et al., 2004). Tal medida de sobreposição tem sido amplamente utilizada para avaliar a robustez de algoritmos de segmentação de imagem (CRUM; CAMARA; HILL, 2006), assim como a utilização do conceito de sobreposições de conjuntos com a utilização de métricas de precisão e revocação, por não levarem em consideração os acertos de verdadeiros negativos, os quais seriam ineficazes ao comparar segmentações.

Na análise de resultados, duas imagens binárias, uma obtida da segmentação automática pelo método proposto e outra manualmente criada por um especialista, serão comparadas. A partir comparação entre as imagens, serão obtidos os valores de verdadeiro positivos (VP), falso positivos (FP) e falso negativos (FN), definidos a seguir:

- VP representa a quantidade de verdadeiros positivos, que são os valores nos quais a segmentação automática e manual tiveram intersecção.
- FP a quantidade de falsos positivos, que são os valores nos quais a segmentação automática não teve intersecção com a segmentação manual.
- FN a quantidade de falsos negativos, que são os valores nos quais a segmentação manual não teve intersecção com a segmentação automática.

Para a validação da proposta, as métricas do valor médio das medidas de DSC, erro relativo (ER), precisão, revocação e F1-score serão utilizadas para promover a comparação com a marcação manual.

2.6.1 DSC

A medida de similaridade de DSC, é uma métrica, cujo valor é diretamente proporcional à intersecção das regiões marcadas e inversamente proporcional à soma ou união dessas regiões e produz valores entre 0 e 1. Coeficientes como o DSC se concentram em medir a similaridade, baseados na contagem das concordâncias (positivas ou negativas), existentes entre os elementos (ALBUQUERQUE et al., 2016):

$$DSC = \frac{2VP}{2VP+FP+FN}. \quad (2.11)$$

2.6.2 ER

A métrica é utilizada para a obtenção dos valores classificados erroneamente em relação à segmentação esperada (TAN; YAN; ZHANG, 2014), e é calculado como:

$$ER = \frac{FP+FN}{VP+FN}. \quad (2.12)$$

2.6.3 Precisão

A precisão denota a proporção de predições positivas que são realmente positivas (POWERS, 2011), também chamada de valor preditivo positivo (FAWCETT, 2006) e é calculado como:

$$\text{Precisão} = \frac{VP}{VP+FP}. \quad (2.13)$$

2.6.4 Revocação

A medida de revocação é usada para identificar todos os casos classificados como positivos e que são realmente positivos, por isso também é chamado de taxa de verdadeiros positivos (FAWCETT, 2006), e é calculada como:

$$\text{Revocação} = \frac{VP}{VP+FN}. \quad (2.14)$$

2.6.5 F1-score

A métrica F1-score corresponde à média harmônica ponderada entre as medidas de precisão (Subseção 2.6.3) e revocação (Subseção 2.6.4) de um sistema de classificação binária

(POWERS, 2011). Essa métrica é calculada como:

$$F1\text{-score}=2\left(\frac{\text{Precisão}\cdot\text{Revocação}}{\text{Precisão}+\text{Revocação}}\right). \quad (2.15)$$

A métrica F1-score é um valor numérico único, capaz de resumir o desempenho de um sistema. Tal medida produz um valor baixo se tanto a precisão quanto a revocação também tiverem um valor baixo, fazendo dela uma medida eficaz para se comparar as segmentações obtidas automaticamente com as segmentações realizadas manualmente.

2.6.6 Regressão

O modelo estatístico de uma regressão linear simples busca obter a reta que melhor se ajusta a seus dados, ele é criado a partir de n pares de valores de duas variáveis, X_i e Y_i , com $i=1, 2, 3, \dots, n$. Se Y for admitido como uma função linear de X , então pode-se estabelecer uma regressão linear simples, cujo modelo estatístico é definido por:

$$Y_i = \alpha + \beta X_i + u_i, \quad (2.16)$$

em que α e β são parâmetros correspondentes ao coeficiente linear da reta e ao coeficiente angular de reta, respectivamente; X é a variável independente, Y é a variável dependente e u_i corresponde ao valor do erro (HOFFMANN et al., 2016).

Para encontrar a linha que melhor se ajusta aos dados, ou seja, a linha que resulta na menor diferença entre os pontos observados, a soma das diferenças verticais entre os valores previstos pela linha e os dados que foram efetivamente observados é calculada. Porém, visto que os valores podem ser positivos ou negativos e, portanto, podem se cancelar quando somados, para contornar tal problema, tais diferenças são elevadas ao quadrado antes de serem somadas. Usando esses valores, é feita a avaliação do quão bem a linha está se ajustando aos dados; neste caso, se as diferenças ao quadrado forem grandes, a linha não é considerada representativa, caso contrário, ela é considerada representativa. Tal técnica é chamada de método dos mínimos quadrados (FIELD, 2009).

Após determinar a linha que melhor se ajusta aos dados, é feito o cálculo de avaliação do quão bem os dados observados se relacionam à linha. Para a avaliação, são utilizados três valores, SS_T , SS_R e SS_M , sendo que o primeiro corresponde a soma total dos quadrados, que é obtida pelas diferenças entre os dados observados (X_i) e a média dos valores de Y ; o segundo corresponde à soma dos quadrados residuais, que é obtida pelas diferenças entre os dados observados (X_i) e a linha de regressão e por último, o SS_M , que corresponde a soma dos quadrados

do modelo e é obtida pelas diferenças entre o valor médio de Y (SS_T) e a linha de regressão (SS_R). A partir dos valores de SS_T e SS_M , é calculado o valor R^2 , que representa o percentual de variação dos valores previstos:

$$R^2 = \frac{SS_M}{SS_T}, \quad (2.17)$$

Para uma regressão linear simples, a obtenção de coeficiente de correlação de *Pearson* é obtido pela raiz quadrada de R^2 , em que o coeficiente de correlação fornece uma boa estimativa da aderência do modelo de regressão e R^2 dá uma boa medida do valor desse relacionamento (FIELD, 2009).

2.7 Considerações finais

Este capítulo apresentou informações a respeito do processo de formação e aquisição das imagens de tomografia computadorizada, além de informações e conceitos teóricos sobre as técnicas utilizadas nesta pesquisa. No capítulo seguinte são apresentados alguns trabalhos propostos na literatura para a segmentação de tecidos da coxa e do abdômen em imagens de ressonância magnética e tomografia computadorizada.

Capítulo 3

REVISÃO BIBLIOGRÁFICA

Este capítulo descreve alguns dos trabalhos propostos na literatura para a segmentação de tecidos da coxa e abdômen em imagens de ressonância magnética e tomografia computadorizada.

3.1 Visão Geral

Visto que o objetivo desta pesquisa é a segmentação e quantificação dos tecidos da coxa e abdômen em imagens de TC, esta revisão da literatura é organizada de maneira a apresentar resumidamente as principais pesquisas e resultados obtidos para o caso destas duas regiões anatômicas.

3.2 Segmentação abdômen

Os principais tecidos adiposos presentes no abdômen são: o tecido adiposo visceral (TAV) e o tecido adiposo subcutâneo (TAS) que, conjuntamente, formam o tecido adiposo total (TAT). A obesidade visceral, por ser um fator contribuinte para a resistência insulínica (CHAN et al., 1994) e doenças cardíacas, é considerado o tipo mais importante de obesidade abdominal.

O TAV é um depósito de gordura encontrado no abdômen e entre as vísceras. O acúmulo em grandes quantidades deste tecido pode interromper o fluxo de sangue para órgãos abdominais, como o fígado, diminuindo e atrapalhando suas funções (WAJCHENBERG, 2000). O excesso da TAV também está relacionado a diabetes tipo 2 e à síndrome metabólica (GAMI et al., 2007), que por sua vez é um grande fator de risco para doença arterial coronária, além de várias outras doenças relacionadas ao acúmulo de placas nas paredes da artéria (OHSHIMA et al., 2008).

Existe uma alta correlação entre o volume de gordura visceral e o desenvolvimento de doenças cardíacas (SHIMOMURA et al., 1996; ORGANIZATION. et al., 1999), o que torna a quantificação de tal gordura extremamente importante no diagnóstico dessas doenças. Devido à medição do TAV ser de difícil realização na prática clínica, existem medidas que buscam substituir o seu cálculo, como o índice de massa corporal (IMC) e o cálculo da área total de gordura, porém a acurácia de tais medidas ainda é controversa na literatura médica (NEMOTO et al., 2014).

Além do IMC, que apenas visa substituir o cálculo do volume da TAV, existem também outras técnicas, como a análise de impedância bioelétrica (AIB) (JACKSON et al., 1988), a RM e a TC. A técnica de impedância tem sido muito utilizada em diagnósticos de obesidade por conseguir quantificar o TAV utilizando a capacidade da resposta bioelétrica do corpo, porém existem poucos relatos de que as medidas obtidas usando esta técnica realmente se correlacionam corretamente com as medidas volumétricas dos tecidos (IDA et al., 2013). A RM pode ser utilizada para a geração de imagens transversais do abdômen, as quais podem ser subsequentemente processadas por algum software de edição de imagens para o cálculo do volume de TAV. No entanto, o uso clínico da RM para a quantificação dos tecidos é limitado devido ao seu alto custo financeiro e longo tempo para a aquisição das imagens (KAMEL et al., 1999). Finalmente, a TC produz imagens capazes de distinguir os tecidos adiposos de outros tecidos usando os níveis de intensidade de HU, e em alguns casos, utilizando exposição à radiação ionizante, é capaz de produzir imagens nas quais o TAV e TAS podem ser quantificados diretamente (TOKUNAGA et al., 1983). Apesar de existirem e serem citados métodos capazes de fazer a quantificação do TAV, a TC é considerada o padrão ouro em testes clínicos devido a sua alta resolução espacial e bom contraste entre os tecidos, possibilitando, assim, uma alta acurácia na medição (POSITANO et al., 2009).

3.2.1 Trabalhos Correlatos

Alguns trabalhos foram propostos na literatura para a segmentação e quantificação de TA em imagens de TC. Pednekar et al. (2005), por exemplo, utilizaram um *framework* de segmentação de imagens baseado na técnica *fuzzy* para segmentação e quantificação automática do TAT abdominal. O *framework*, inicialmente desenvolvido por Saha e Udupa (2001), captava elementos disjuntos (uma região que se separou, mas faz parte da mesma estrutura) com base na sua força de conexão. Posteriormente, o modelo foi adaptado pelos autores com a proposta de diminuir a restrição da conexão *fuzzy* e permitir uma segmentação mais global, de maneira a combinar informações de intensidade e textura com elementos disjuntos locais dentro de uma

classe de gordura. Tal método foi proposto pois, de acordo com os autores, uma segmentação baseada em limiares não seria suficientemente robusta. Ao invés de aplicar um limiar global, o *framework* adapta o valor de limiar localmente utilizando a distância de *Mahalanobis* de informações de intensidade (LAWS, 1980) e textura (MANJUNATH; MA, 1996) para medir a semelhança entre pixels. Uma combinação mais discriminatória de características de textura, para regiões de objetos específicos, é determinada para a fase de treino. A seguir, é escolhido um ponto “semente” utilizando a técnica *Active Shape Models* (ASM) (COOTES et al., 1995) e, finalmente, são calculadas estatísticas ao redor de cada ponto. Os autores utilizaram 400 imagens de TC extraídas entre a quarta e quinta vértebras lombares (L4-L5) de 80 pacientes (5 imagens para cada um). Para a análise dos resultados, os autores separaram as imagens de 40 pacientes para teste e 40 para treino e validaram o estudo utilizando a comparação dos resultados obtidos pelo método automático com as marcações manuais realizadas por um especialista em 20 pacientes. As métricas de acurácia, valores de verdadeiro positivo (VP), verdadeiro negativo (VN), fração de falso positivo (FFP) ($FFP = 100 \cdot FP / (VP + FN)$) e fração de falso negativo (FFN) ($FFN = 100 \cdot FN / (VP + FN)$) foram apresentados graficamente, e os principais resultados ficaram entre 95 – 100% de acurácia, 94 – 99% de verdadeiros positivos, 88 – 100% de verdadeiros negativos, 2 – 10% de FFN e de 3 – 18% para FFP.

Mais tarde, Bandekar, Naghavi e Kakadiaris (2006) propuseram uma melhoria do trabalho anterior (Pednekar et al. (2005)), utilizando a mesma técnica, porém com a incorporação da remoção automática de artefatos relacionados à aquisição e diferenciação automática do TAS e do TAV. No novo experimento, os autores utilizaram 200 imagens de TC, também extraídas entre a quarta e quinta vértebras lombares (L4-L5) de 40 pacientes (5 imagens para cada um) e validaram a técnica comparando os resultados obtidos pelo método automático com as marcações manuais realizadas por um especialista nos 40 pacientes. As métricas utilizadas para os resultados mantiveram-se as mesmas utilizadas em Pednekar et al. (2005). Para TAS e TAV, a acurácia foi de 98,28% e 97,66%, respectivamente; a média de verdadeiros positivos foi de 99,43% e 99,14% e, por fim, a média de verdadeiros negativos foi de 90,01% e 86,14%.

No mesmo ano, Zhao et al. (2006) propuseram uma técnica para a segmentação da TAS e TAV utilizando informações extraídas de linhas digitais delineadas do centro ao perímetro do corpo utilizando imagens de TC. Para cada fatia os autores fazem um pré-processamento para a obtenção da pele que contorna a gordura total utilizando limiares e filtros morfológicos. Após a obtenção do contorno, o centro de massa da região foi determinado e linhas saindo do centro e indo até o contorno da pele, com um ângulo de 3° entre si, foram delineadas. Para cada linha, foi obtido um perfil de intensidade que continha um histograma para cada nível de HU. A partir da análise do perfil foram definidos dois pontos: o que toca a pele e o que toca o músculo.

Com os dois pontos, foi traçada uma nova reta, a qual continha somente gordura subcutânea. Porém, para a correção das retas delineadas erroneamente, pela presença anormal da TAS ou alguma estrutura óssea, foi proposto um algoritmo de suavização. Tal algoritmo analisou o comprimento das retas e verificou se elas eram semelhantes com a finalidade de corrigir as retas mal delineadas. Após as correções, os pontos de músculo foram interligados e os valores da TAS e TAV foram obtidos via limiarização dos valores de HU. Para a análise dos resultados os autores utilizaram 419 fatias de TC extraídas entre as vértebras L3-L4 de 9 pacientes e compararam com as marcações manuais realizadas por um radiologista. As diferenças percentuais obtidas entre as duas marcações foram de 0,65% para TAS e 1,54% para TAV.

Em outro trabalho, Nemoto et al. (2014) propôs a segmentação automática de gordura visceral na região do abdômen utilizando filtros morfológicos de dilatação e erosão, limiarizações e análise de componentes conexos. Para a obtenção dos resultados, as imagens foram reescaladas para metade de seu tamanho original a fim de diminuir o tempo de processamento e a região do tronco foi extraída utilizando limiares e filtros morfológicos. A seguir, a mesma região foi segmentada em osso, músculo, gordura e ar utilizando processos de limiarização. Nas regiões de osso, músculo e ar um filtro de fechamento foi aplicado e a região resultante foi considerada visceral e, finalmente, foi calculado o volume da região visceral. Para a análise dos resultados, os autores utilizaram 24 imagens de TC do corpo todo e, com o propósito de obter pacientes que vão de magros a obesos dos dois gêneros, três pacientes foram selecionados de cada um dos subgrupos estratificados por peso e sexo. Para a validação do estudo foram utilizadas medições manuais produzidas por um especialista sob supervisão de um secundário. Os autores obtiveram como resultados coeficientes de correlação iguais a 0,99998 e 0,9995 para os subgrupos masculino e feminino, respectivamente; os coeficientes foram obtidos entre o TAV medido pelo especialista e o TAV medido automaticamente.

Recentemente, Kim et al. (2016) propuseram a segmentação automática da gordura visceral da região do abdômen utilizando a técnica *Convex Hull*¹ (GRAHAM; YAO, 1983), seguida de etapas de pós-processamento para corrigir a detecção de pixels distantes do músculo. A metodologia iniciou-se com a eliminação de regiões desnecessárias que poderiam causar erros posteriores, como o ar. A seguir, o músculo foi localizado utilizando limiarizações e em seguida, um filtro morfológico de abertura foi aplicado para a exclusão da pele. Então, o algoritmo *Convex Hull* foi utilizado para detectar o menor caminho (GRAHAM; YAO, 1983) que delineasse a região muscular. Erros no delineamento foram corrigidos utilizando análises de proximidade dos pixels com o músculo. Finalmente, regiões de não gordura, como espinha, costelas e pélvis, foram eliminadas com base em limiares de HU. Para a análise dos resultados,

¹*Convex Hull*: Busca o menor polígono convexo que contenha a área desejada.

os autores utilizaram 100 imagens de TC obtidas do *National Cancer Center of Korea*. Para a validação da técnica foram utilizadas medidas manuais das regiões de TAV e TAS delimitadas por dois especialistas. Os autores compararam seus resultados utilizando o coeficiente de similaridade de Dice (*Dice similarity coefficient* - DSC) para duas medições dos especialistas. Quando comparado ao primeiro especialista, os valores de DSC foram de 99%, 98% e 97% para o TAT, TAS e TAV, respectivamente, e quando comparados ao segundo especialista, os valores de DSC foram de 98%, 98% e 97%, também para TAT, TAS e TAV, respectivamente.

3.3 Segmentação coxa

A coxa possui diversos tecidos adiposos, como o TAS, TA-Intramuscular e TA-Intermuscular. No entanto, devido à englobar e permear os bloqueios do músculo esquelético, o qual compartilha uma conexão vascular direta, o TA-Intermuscular está relacionado ao desenvolvimento de diversas doenças, o que faz com que esse tecido seja considerado um dos mais importantes da coxa. O TA-Intermuscular é um depósito de gordura encontrado dentro da fáscia que contorna a musculatura da perna; e a fáscia, por sua vez, é membrana fibrosa que expande as bainhas aos músculos das coxas (DURHEIM et al., 2008).

O TA-Intermuscular tem sido considerado um importante preditor do metabolismo, função muscular e de mobilidade do corpo (ADDISON et al., 2014). Níveis elevados do tecido estão associados à resistência insulínica (GOODPASTER; THAETE; KELLEY, 2000; GOODPASTER et al., 2003; YIM et al., 2007), a qual pode aumentar as chances do desenvolvimento de diabetes tipo 2 (ADDISON et al., 2014), e estão inversamente associados às atividades físicas, o que pode contribuir para diminuição da mobilidade (GOODPASTER et al., 2008) e perda de força (YOSHIDA; MARCUS; LASTAYO, 2012; MANINI et al., 2007).

Estudos relatam que adultos com idade mais avançada e que possuem níveis elevados do TA-Intermuscular nos músculos locomotores apresentam maior fraqueza muscular, redução da função de mobilidade (GOODPASTER B.H. CARLSON et al., 2001; GOODPASTER et al., 2006) e aumento do risco de limitação de mobilidade no futuro (VISSER et al., 2005, 2002). Outra importante doença associada ao acúmulo excessivo do tecido é a osteoartrite (OA) do joelho, que é um tipo de doença degenerativa das articulações, incluindo cartilagem articular e osso subcondral, e é a artrite mais prevalente em pessoas idosas (TAN et al., 2016).

Portanto, a quantificação de tecidos da coxa, como o TA-Intermuscular, são de suma importância para o diagnóstico e prevenção de doenças. De fato, a coxa é considerada a localização anatômica perfeita para a avaliação do TA-Intermuscular pois o volume do meio da coxa é o

melhor preditor para TA-Intermuscular do corpo inteiro (RUAN et al., 2007). Portanto, uma avaliação quantitativa precisa do tecido faz-se crucial em muitas análises médicas e clínicas, como a análise de qualidade funcional das pernas, disfunção metabólica ou diagnóstico de OA do joelho. As medições mais comuns para a região do TA-Intermuscular são realizadas usando imagens de TC ou RM, as quais são apresentadas a seguir.

3.3.1 Trabalhos Correlatos

Positano et al. (2009) propuseram uma segmentação 2D de imagens T1- w de RM para o TA-Intermuscular e músculo utilizando a técnica de cluster *fuzzy*, contornos ativos baseados em *gradient vector flow* (GVF), e um modelo de mistura de gaussianas. A metodologia usada pelos autores inicia-se com a obtenção das máscaras de fundo/osso, gorduras e músculo usando o algoritmo *fuzzy c-mean* (FCM), que faz classificação não supervisionada dos pixels da imagem sem utilizar valores pré-definidos de limiares. Como resultado foram obtidos três mapas para as respectivas regiões. Utilizando o mapa de fundo/osso foi feita a separação das coxas com a criação de um perfil de intensidades no eixo x , a partir do qual foi definido um limiar e três intervalos (s_1 , s_2 e s_3). O centro do segundo intervalo (s_2) foi utilizado para a separação das coxas. Para cada coxa foram produzidos mapas de borda de gordura e fundo/osso com base nos mapas obtidos no passo anterior e o algoritmo *snake* (GVF) foi utilizado para a obtenção dos contornos do TAS, fáscia e osso. Utilizando o mapa de bordas de gordura como força externa e uma circunferência ao redor da coxa como inicialização, o algoritmo convergiu para o contorno externo do TAS. A partir desse resultado, e utilizando o mesmo mapa em conjunto com o contorno obtido no passo anterior como inicialização, o algoritmo convergiu para a obtenção do contorno da fáscia e utilizando o resultado do contorno da fáscia como inicialização e o mapa de bordas de osso, foi obtido o contorno do osso. Com os contornos obtidos, os autores quantificaram a TA-Intermuscular e músculo (dentro da mesma região) usando um modelo de mistura de gaussianas, com parâmetros estimados pelo algoritmo EM. Utilizando essa abordagem, os autores conseguiram encontrar as duas distribuições que, quando combinadas, produziram os melhores resultados que caracterizavam classes de gordura e músculo. Para a validação do método, os autores utilizaram 20 pacientes obesos com diferentes números de fatias (variando entre 22 e 37) e que totalizou 636 imagens. Os resultados obtidos foram comparados com marcações manuais produzidas por um especialista. Os autores obtiveram menos de 2% para o coeficiente de variação da TAS, menos de 1% para o músculo e menos de 5% para a TA-Intermuscular.

Alguns anos depois, Tan, Yan e Zhang (2014) criaram um *framework* para segmentação de TA-Intermuscular, TA-Intramuscular e músculo utilizando imagens volumétricas de TC e RM

da coxa usando um modelo de misturas gaussianas variável para identificar os tecidos primários, seguido de um modelo de contornos ativos para a distinção entre os tecidos adiposos com TAS, TA-Intermuscular e TA-Intramuscular e por último, utilizou a classificação dos tecidos para medir a fração de tecidos adiposos na coxa. A metodologia utilizada inicia-se com a remoção do *bias-field* usando o algoritmo N4 (TUSTISON et al., 2010), que assume que o *bias field* é um sinal multiplicativo que suaviza o sinal originalmente emitido pelo tecido do paciente em uma determinada localidade e a seguir, foi aplicado um modelo de misturas gaussianas variável (*Variational Inference for the Gaussian Mixture Model* - VBGMM) (BISHOP, 2006). O algoritmo foi aplicado para a obtenção de uma separação dos tecidos primários, como adiposo, osso e músculo. Com os tecidos primários separados foi então utilizado um modelo de contornos ativos (*Active contour model* - ACM) para a separação dos tecidos adiposos específicos, cujo objetivo principal foi eliminar o TAS e iniciar a segmentação da região muscular. O modelo foi construído utilizando energias internas e externas e, para tornar a superfície convergente para os limites dos objetos, a energia funcional foi diminuída (LÜRIG; KOBELT; ERTL, 2000). Utilizando as segmentações da região do TAS obtidas do ACM, foi utilizado o *Selective Binary Gaussian Filtered Regularized Level Set* (SBGFRLS) para segmentar as regiões musculares de maneira individual e por último, os autores utilizaram a classificação dos tecidos obtidas nas etapas anteriores para medir a fração dos tecidos inter e intramusculares em relação ao músculo. Para validar a técnica, foram feitos experimentos em quatro imagens volumétricas das coxas, sendo três de RM e uma de TC, e os resultados foram comparados com marcações manuais. Os autores obtiveram valores de DSC de 0,87 e 0,86 para a TA-Intermuscular e TA-Intramuscular, respectivamente, em imagens de RM e valores de 0,92 e 0,89 para a TA-Intermuscular e TA-Intramuscular, respectivamente, em imagens de TC.

A fim de corrigir os problemas da técnica proposta em Tan, Yan e Zhang (2014), dois anos depois, Tan et al. (2016) propuseram novamente a quantificação do TA-Intermuscular, mas dessa vez utilizando um modelo deformável orientado por detecção baseada em aprendizagem. A metodologia inicia-se com a obtenção da região que delimita os músculos e a utiliza como inicialização do modelo. A região foi encontrada utilizando o algoritmo FCM, que classifica os pixels de maneira não supervisionada, seguida da aplicação do algoritmo GVF-snake, que foi capaz de refinar a borda da região muscular usando a evolução do modelo, permitindo assim, um contorno mais conectado e suavizado. A seguir, a fásia foi detectada utilizando o algoritmo de classificação *random forest* (BREIMAN, 2001). O algoritmo utilizou características de textura e orientações locais e globais, além da posição do centro da coxa, extraídas de um conjunto de fatias das duas coxas, que mostraram grande correlação entre si, a fim de aumentar a quantidade de características das amostras de treinamento. Para cada amostra foram utilizadas

as marcações manuais chamadas de positivas e em cada amostra positiva, foram traçados pontos para frente e para trás em intervalos iguais chamadas de negativas. Após o treinamento, foram detectados pontos a partir da inicialização para diminuir a área e melhorar a eficiência, além de focar a detecção em um conjunto esparsos de pontos. O detector buscou então ir para a direção em que cada ponto tinha maior probabilidade pertencer à fáscia. Finalmente, foram feitos ajustes nos resultados obtidos com a introdução de uma restrição de esparsidade (ZHANG et al., 2012), que foi utilizada para otimizar a deformação do modelo e também para encaminhar o algoritmo de volta para a primeira etapa, caso ele não tenha convergido. Para validação, os autores utilizaram um conjunto de 40 pacientes com 80 imagens 3D da coxas de RM e os resultados foram comparados com o trabalho anterior dos autores (TAN; YAN; ZHANG, 2014) em que a medida de DSC aumentou para 0,9784.

Kullberg et al. (2017) recentemente propuseram uma nova técnica para a quantificação de tecidos da coxa e abdômen em imagens de TC. Os autores criaram uma técnica intitulada *Inside Lean Tissue* (ILT) para separar o TAS do TA-Intermuscular nas coxas e o TAS do TAV no abdômen. Sua metodologia propõe que, para cada pixel na imagem, tecidos magros sejam contados e rastreados em diferentes direções. A seguir, sua ocorrência é usada para calcular um mapa de probabilidade, que corresponde à quantidade de tecidos magros que envolvem o pixel analisado. Os autores usaram 1089 imagens de TC do abdômen e subgrupos de 50 pacientes foram selecionados aleatoriamente para validação dos resultados. Os valores de DSC para o abdômen foram de 0,98 e 0,97 para TAS e TAV, respectivamente. Para a coxa, os autores utilizaram apenas 57 imagens nas quais a fáscia estava visível (aproximadamente 5% do conjunto de dados) e obtiveram 0,97 e 0,88 de DSC para TAS e TA-Intermuscular, respectivamente.

3.4 Discussão

Esta seção apresentou alguns métodos propostos na literatura para a segmentação e quantificação de tecidos presentes na região do abdômen e da coxa. Apesar dos resultados obtidos terem demonstrado altas taxas de acerto, até o momento, não há nenhuma ferramenta disponível para a comunidade médica que faça a segmentação automática de tais tecidos. Além de, em alguns casos, as bases de dados utilizadas pelos autores não estarem disponíveis para a reprodução e comparação de técnicas. É possível observar também que, para o exame de TC da coxa, poucos trabalhos foram desenvolvidos, sendo o enfoque principal dado para o uso de imagens de RM. No caso do trabalho de Kullberg et al. (2017), embora os autores tenham usado imagens de TC, a quantificação do TA-Intermuscular foi feita apenas para 5% das imagens da base, com imagens selecionadas sem a descrição de um critério transparente.

3.5 Considerações Finais

Nesta seção foram apresentadas algumas abordagens recentes propostas na literatura para a segmentação de tecidos nas regiões da coxa e abdômen em imagens de RM e TC. Foram descritas as técnicas, as formas de avaliação, as bases de dados utilizadas e os resultados obtidos por cada trabalho selecionado. Além disso, foi apresentada uma breve discussão sobre as técnicas. Embora muitas das técnicas descritas tenham relatado um desempenho satisfatório, é importante notar que elas possuem algumas limitações importantes (já discutidas). Com base na discussão anterior, nesta pesquisa desenvolvemos uma técnica visando suprir as limitações citadas, cuja metodologia é apresentada no capítulo a seguir.

Capítulo 4

METODOLOGIA

Este capítulo apresenta a descrição das bases de dados utilizadas e as técnicas desenvolvidas para a segmentação automática dos tecidos da coxa e abdômen.

4.1 Visão Geral

Nesta pesquisa foi desenvolvida uma técnica computacional automática para segmentar tecidos da coxa e do abdômen em imagens de TC. Para tal finalidade, foram utilizadas uma combinação de informações de intensidade, usando o MMFG e limiarizações, e espacial das imagens, analisando-se a localização dos voxels nas imagens para a segmentação. No Capítulo 2 foi apresentada a parte teórica dos métodos utilizados para o desenvolvimento da técnica de segmentação dos tecidos adiposos, como filtros morfológicos, MMFG e a técnica de linhas digitais, desenvolvida especialmente para a análise da localização dos voxels utilizada nesta pesquisa. A Figura 4.1 contém um fluxograma que indica a sequência de etapas utilizada no desenvolvimento da técnica de segmentação. Cada etapa é detalhada nas seções a seguir.

Com base na revisão bibliográfica das técnicas de segmentação dos tecidos da coxa e abdômen apresentadas no Capítulo 3, nota-se que, para ambos os casos, o principal foco é a detecção da fáschia nas imagens, cujos valores de intensidade se encontram na mesma faixa de outros tecidos adiposos. Além disso, por ser uma membrana muito fina, a fáschia não pode ser visualizada por completa na imagem. Portanto, o algoritmo aqui proposto tenta prever a localização da fáschia. Considerando-se somente os tecidos adiposos, na coxa, a fáschia delimita a região que separa o TA-Intermuscular do TAS, para o abdômen, juntamente com os músculos, ela delimita a região visceral, que separa o TAS do TAV. Em ambos os casos, a quantificação dos tecidos serve para o auxílio ao diagnóstico de várias doenças, visto que tais tecidos são considerados reguladores da inflamação e da obesidade.

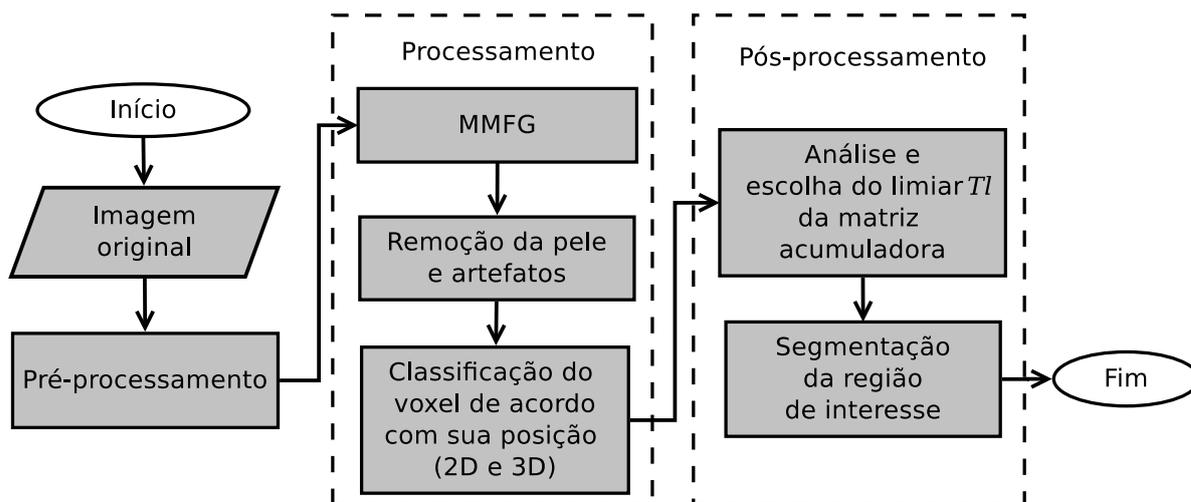


Figura 4.1: Visão geral do fluxograma para a segmentação das regiões de interesse da coxa e do abdômen em imagens de TC.

4.2 Base de Dados

Para a realização deste trabalho de pesquisa, imagens de TC da coxa e abdômen de 72 indivíduos (36 homens, 65.5 anos \pm 14.9, peso 73.6 \pm 11.6; e 36 mulheres, 54.2 anos \pm 14.9, peso 69.6 \pm 11.0) foram obtidas usando um tomógrafo *Multislice (Brilliance CT 16-slice, Phillips)* pertencente ao Hospital Universitário da cidade de São Carlos - SP/BR. Todas as imagens foram armazenadas no formato *DICOM* e possuem as seguintes características de aquisição: matriz imagem de $512 \times 512 \times 10$ voxels, em que o tamanho do pixel no plano, espessura e distância entre as fatias variam de imagem para imagem. Todos os participantes foram informados sobre o uso de suas imagens de TC e outras informações médicas para esta pesquisa e esse estudo foi aprovado pelo comitê de ética em pesquisa com seres humanos de pesquisa da Universidade Federal de São Carlos (número CAAE: 64171617.9.0000.5504).

Do total de 72 exames de TC da coxa e do abdômen, todas as imagens das coxas foram demarcadas por um especialista, com o adicional de que cada exame de TC da coxa compreende as coxas esquerda e uma direita, que foram separadas para esta pesquisa, totalizando 144 imagens de coxas. Diferentemente das imagens das coxas, no caso do TC do abdômen, somente 15 imagens foram demarcadas por um especialista.

4.3 Pré-processamento

O pré-processamento das imagens de TC tem por objetivo obter as máscaras que delimitam as coxas e o abdômen. As etapas de pré-processamento para as imagens de TC da coxa são indicadas na Figura 4.2 e para o abdômen na Figura 4.3. A descrição de cada uma delas é apresentada nas subsecções a seguir.

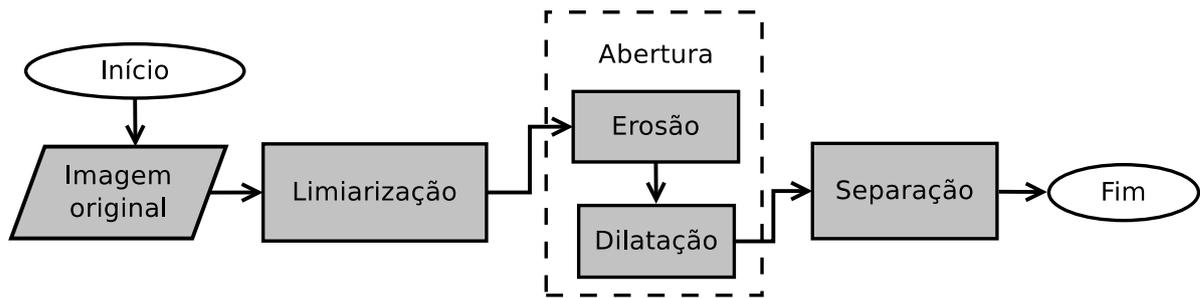


Figura 4.2: Fluxograma das etapas de pré-processamento da coxa.

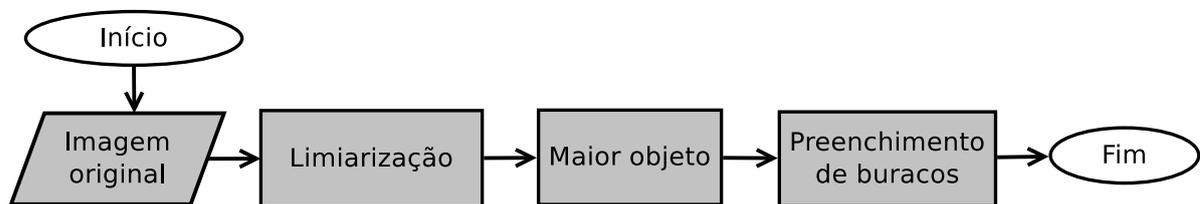


Figura 4.3: Fluxograma das etapas de pré-processamento do abdômen.

4.3.1 Detecção da coxa

Como resultado de um exame de TC da coxa, uma imagem 3D contendo as duas coxas do paciente, além da mesa do tomógrafo, é obtida. Nessa imagem as coxas podem estar muito próximas, ou até mesmo grudadas, havendo, portanto, a necessidade de separá-las. Para a realização desta tarefa, primeiro as bordas da mesa do tomógrafo são removidas da imagem e, em seguida, as coxas são separadas em duas imagens distintas. Essas duas etapas são descritas a seguir.

Para a remoção da mesa e outros pequenos artefatos presentes na imagem, uma técnica de limiarização é utilizada, em que valores maiores que -190 HU são considerados pertencentes

aos objetos de interesse. O valor de HU utilizado para a segmentação da imagem é escolhido de acordo com valores de atenuação pré-definidos para os tecidos da coxa nas imagens de TC, conforme explicitado na Tabela 2.1 - Capítulo 2. Pela Tabela 2.1, valores maiores que -190 HU incluem tecidos adiposos ou musculares, que são os tipos de tecido que irão compor a máscara que delimita a coxa. Portanto, voxels da imagem com valores de intensidade superiores a esse limite são rotulados como pertencentes ao objeto de interesse (branco), enquanto os demais são rotulados como plano de fundo (preto).

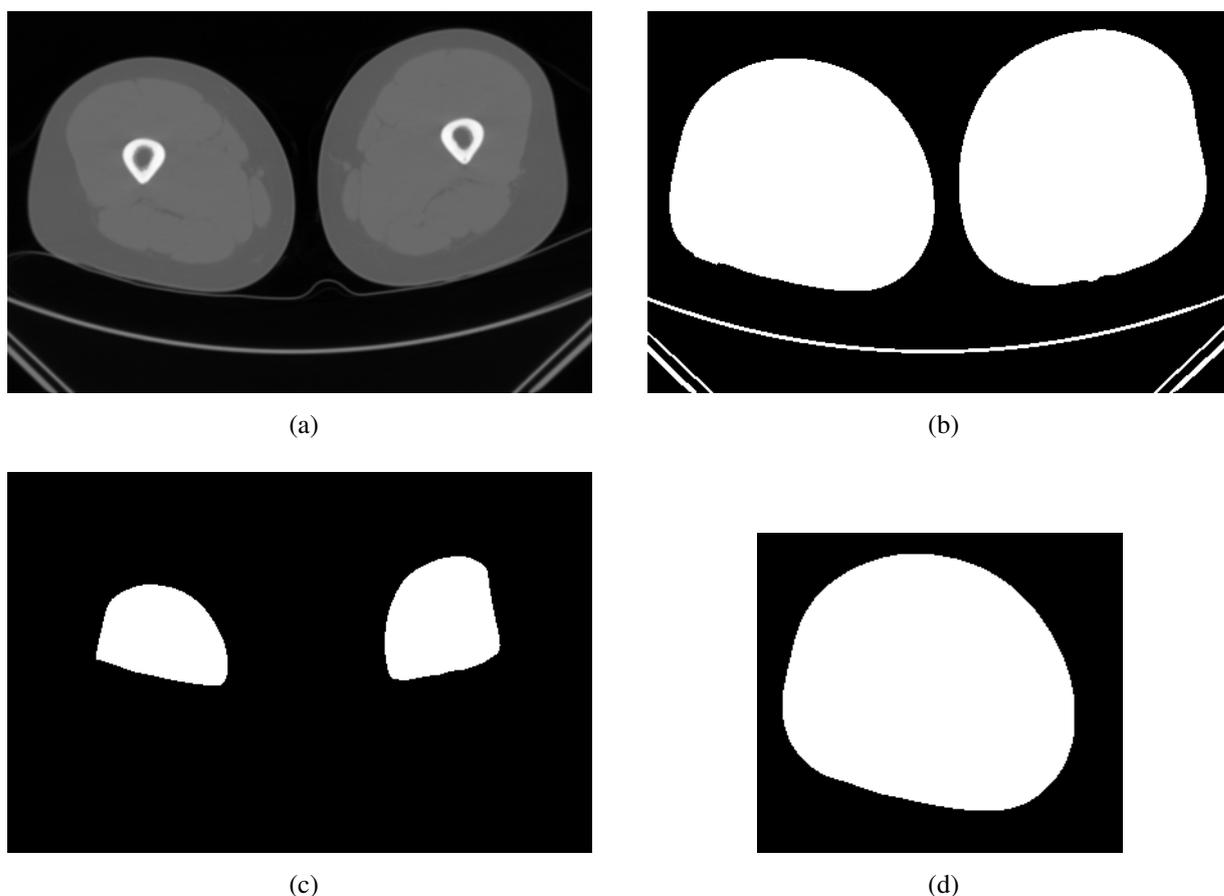
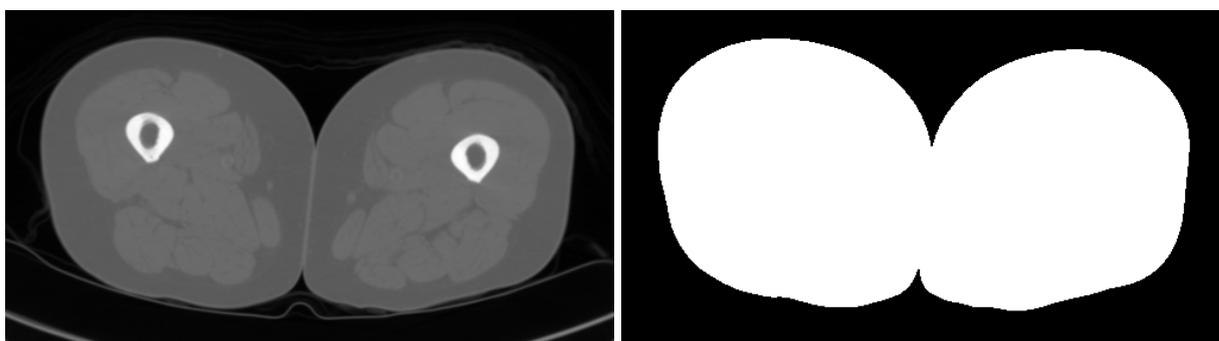


Figura 4.4: a) Imagem de TC da coxa original; b) Resultado da etapa de limiarização; c) Resultado da etapa de erosão e; d) Resultado da dilatação da coxa esquerda.

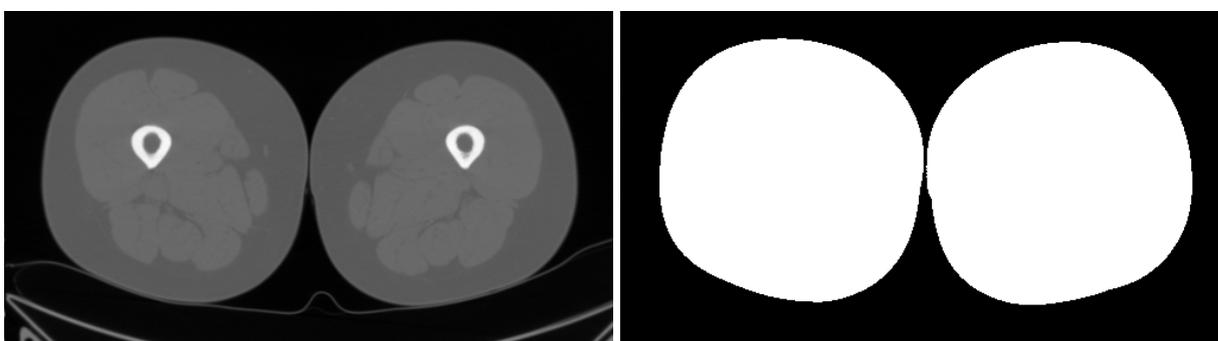
Para a eliminação da mesa do *scanner* de TC (e outros pequenos artefatos), que geralmente aparecem no resultado da binarização da imagem, uma operação de erosão com um elemento estruturante em forma de disco de raio igual a 7 é aplicada. Tal valor foi definido com base em análises experimentais, em que o valor 7 mostrou-se suficiente para eliminar os artefatos indesejáveis. Embora este procedimento elimine as bordas indesejáveis da mesa do *scanner*,

ele também reduz a área da imagem binária (em branco). Portanto, uma operação de dilatação usando o mesmo elemento estruturante da erosão é aplicada à imagem erodida, a fim de que as coxas recuperem a sua forma original. A Figura 4.4 mostra um exemplo do passo a passo descrito.

É fato que, em grande parte das imagens, as coxas já se encontram separadas, conforme o exemplo 4.5b(b). Porém, existem casos em que as coxas se tocam, criando um único objeto binário (Figura 4.5(a)). Para a obtenção de uma segmentação mais apropriada, uma sequência de passos foi desenvolvida e é explicada a seguir.



(a)



(b)

Figura 4.5: Exemplos de imagem de TC (a) com as coxas grudadas (b) com as coxas separadas.

Caso apenas um objeto seja detectado na imagem binária, então, assume-se que as coxas estão grudadas, sendo, portanto, necessário separá-las. Para a separação das coxas, em cada fatia da imagem é feita a detecção de dois pares de pontos, (T1, T2) e (B1, B2), conforme ilustrado na Figura 4.6(a). O ponto T1 corresponde ao primeiro pixel do objeto binário (branco) encontrado fazendo-se uma varredura na metade esquerda da imagem, iniciando-se da esquerda para a direita e de cima para baixo. Da mesma forma, para encontrar o ponto T2, o mesmo procedimento é usado na metade direita da imagem. Em seguida, os pontos (B1, B2) são determinados de forma idêntica à (T1, T2), com a exceção de que foi utilizada uma varredura de baixo para cima ao invés de cima para baixo.

Depois disso, o ponto P1 é definido como o ponto de borda do objeto que está localizado entre os pontos T1 e T2, e que possui o menor valor da coordenada y, enquanto que o ponto P2 é definido como o ponto de borda do objeto, localizado entre os pontos B1 e B2 com o maior valor da coordenada y. Finalmente, as duas coxas são divididas usando uma linha reta formada pelos pontos P1 e P2, conforme mostrado na Figura 4.6 (b).

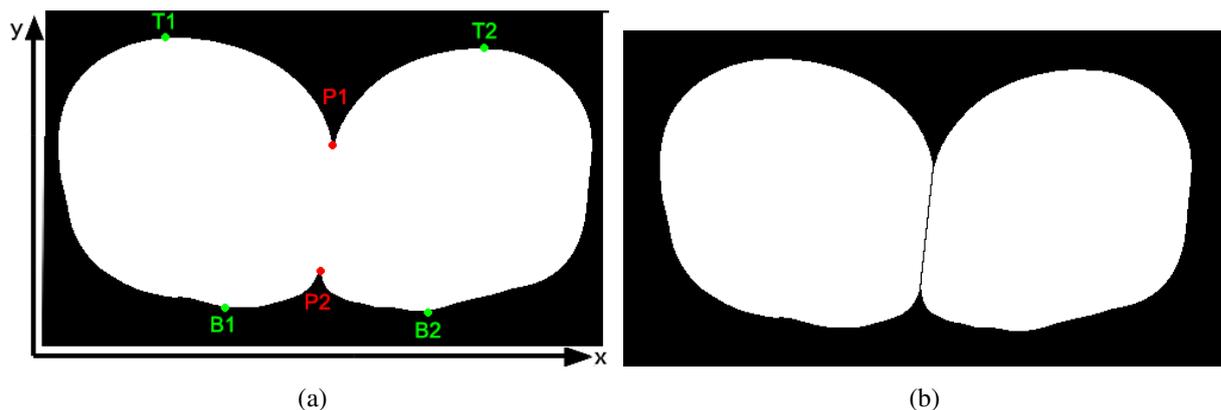


Figura 4.6: Passos para separar as coxas (a) pontos usados no processo de separação das coxas; (b) coxas separadas usando os pontos P1 e P2.

4.3.2 Detecção do abdômen

Nas imagens de TC, os níveis de intensidade dos tecidos possuem valores definidos pela escala de HU, porém, diferentemente das imagens da coxa, no abdômen é comum encontrar bolhas de gases, as quais possuem a mesma intensidade que o ar encontrado no fundo das imagens, o que impossibilita a aplicação de um filtro morfológico de erosão para remoção da mesa e pequenos artefatos. Portanto, para a obtenção da máscara do abdômen, para delimitar a área de processamento, as etapas utilizadas são descritas a seguir.

Primeiramente, a partir da aquisição de uma imagem TC de abdômen, conforme mostra o exemplo da Figura 4.7(a), objetiva-se a obtenção da área abdominal. Nesta etapa é feita uma limiarização que utiliza o mesmo valor de limiar que na primeira etapa de pré-processamento da coxa, em que os voxels com valores maiores que -190 HU recebem o valor 1 (branco) e os menores recebem o valor 0 (preto). Como saída, uma imagem binária contendo o abdômen e alguns artefatos, gerados pelo processo de aquisição, é obtida, conforme Figura 4.7 (b). Em seguida, o abdômen é detectado a partir da detecção do objeto com maior quantidade de voxels conectados. No entanto, as bolhas de gases ainda são visíveis na imagem resultante dessa etapa, conforme mostra a Figura 4.7(c). Por fim, o método *fillholes*, disponibilizado na biblioteca

*Insight ToolKit*¹ (ITK) foi usado, ele é capaz de preencher buracos, que foram gerados bolhas de gases nesse caso, dentro de uma máscara binária, fazendo com que eles se tornem parte da máscara em questão. Como resultado, espaços em preto decorrentes da presença de gases, são removidos, gerando assim, uma melhor representação da máscara binária que delimita o abdômen, conforme mostrado pela Figura 4.7 (d).

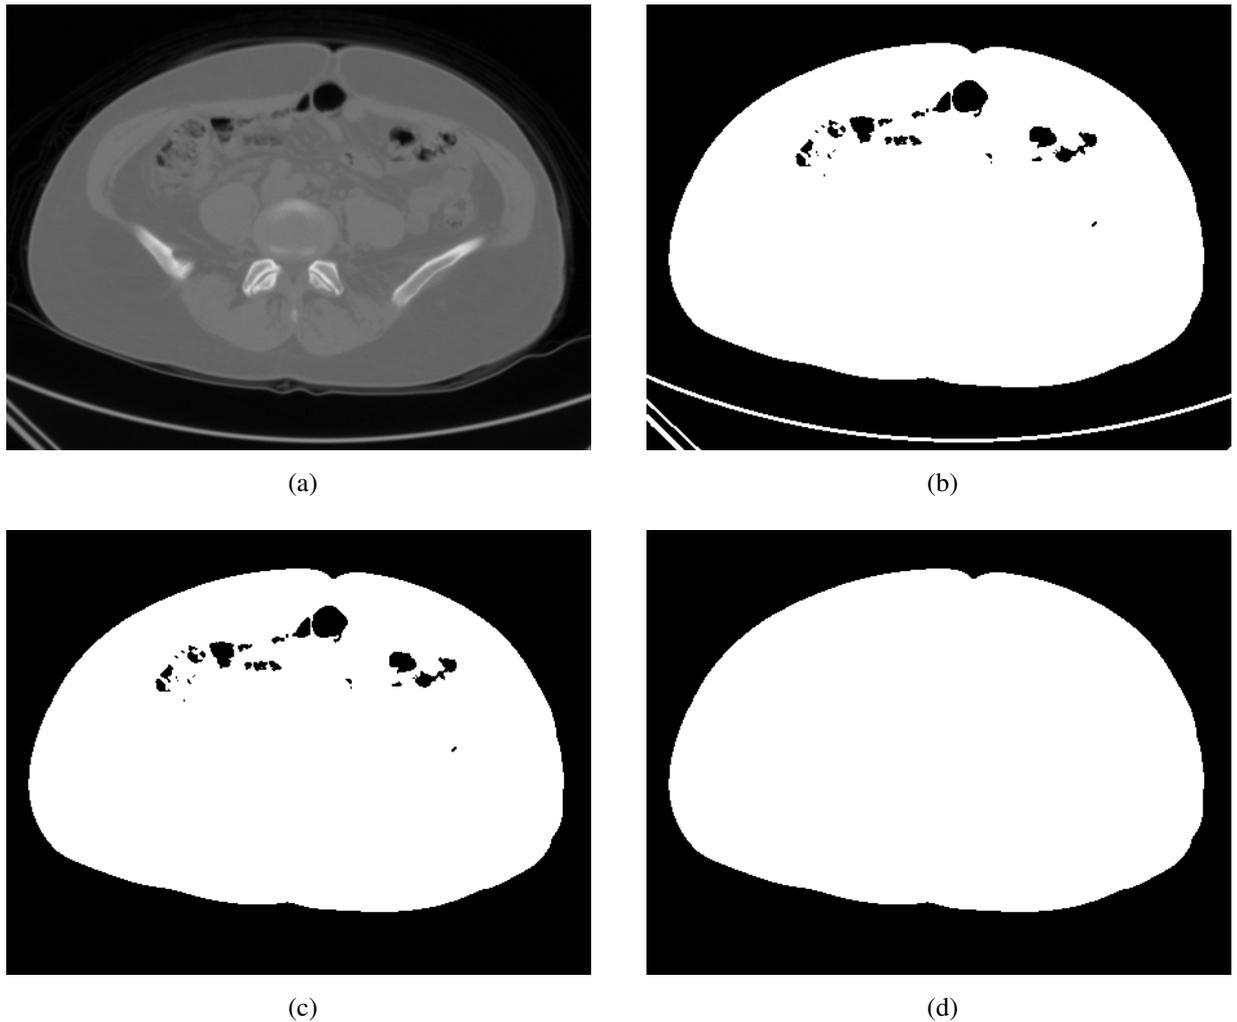


Figura 4.7: a) Imagem de TC do abdômen original; b) Resultado da etapa de limiarização; c) Resultado da etapa de obtenção do maior objeto e; d) Resultado da etapa de preenchimento de buracos.

¹<http://www.itk.org/>

4.4 Método para o processamento das imagens de TC

Nesta etapa, as segmentações das regiões visceral (abdômen) e delimitada pela fásia (coxa) utilizam as mesmas técnicas, portanto, elas são explicadas sem distinção. As imagens de TC originais são utilizadas em conjunto com suas respectivas máscaras binárias como entrada para esse método. Primeiramente, o modelo de mistura finita de Gaussianas (MMFG), usado para estimar as distribuições de probabilidades dos tecidos, juntamente com o classificador MAP são aplicados com o objetivo de separar os voxels de gordura dos demais. Com isso, os voxels são divididos em duas classes: gordura (valor 1) e não gordura (valor 2), e todos os voxels fora da região da máscara (fundo da imagem) continuam com valor 0. Como saída, é obtida uma imagem na qual o TAS, o TAV e o TA-Intermuscular possuem o rótulo 1, e o TA-Intramuscular, em conjunto com os tecidos não adiposos, possuem o rótulo 2, conforme mostram as Figuras 4.8 (a) e 4.9 (a).

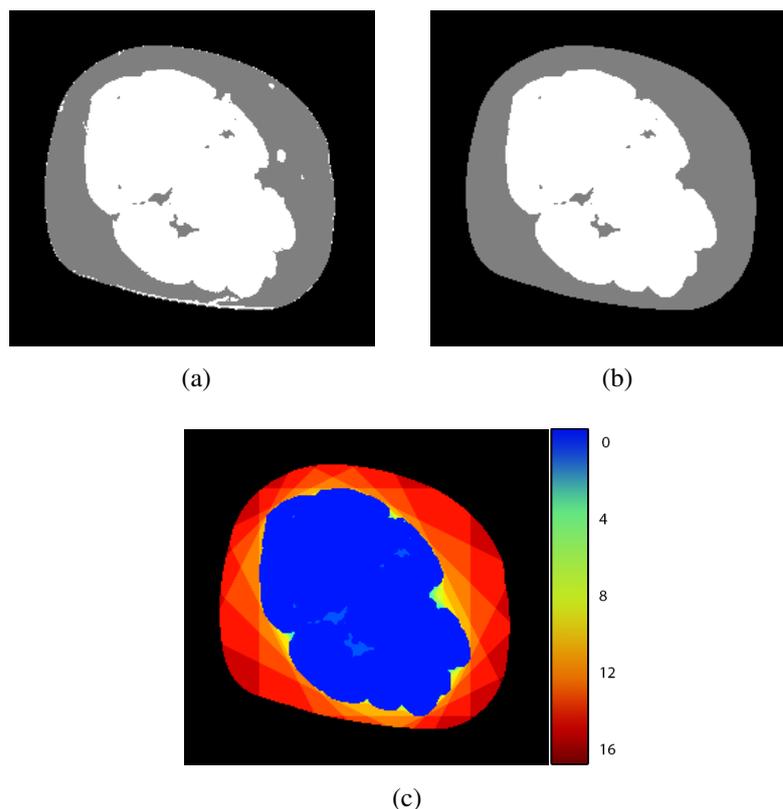


Figura 4.8: Imagens da coxa esquerda. a) Imagem resultante da aplicação do MMFG; b) Imagem resultante da remoção da pele e pequenos objetos; c) Resultado da etapa de classificação dos voxels de acordo com sua posição. Os mapas de cores mostram os valores da matriz acumuladora.

Em seguida, pequenos artefatos gerados da aplicação do MMFG são eliminados aplicando-se uma operação de abertura apenas aos objetos que receberam valor 2. A operação de abertura foi produzida utilizando um elemento estruturante circular de raio igual a 1 apenas para remover pequenos objetos no meio da gordura. A seguir, a pele é removida realizando-se uma verificação dos pixels próximos ao fundo da imagem. Todos os pixels de valor 2 (não gordura) que estão a uma distancia de até 5 pixels do fundo da imagem (valor 0) são removidos ao final desta etapa, conforme mostram as Figuras 4.8 (b) e 4.9 (b).

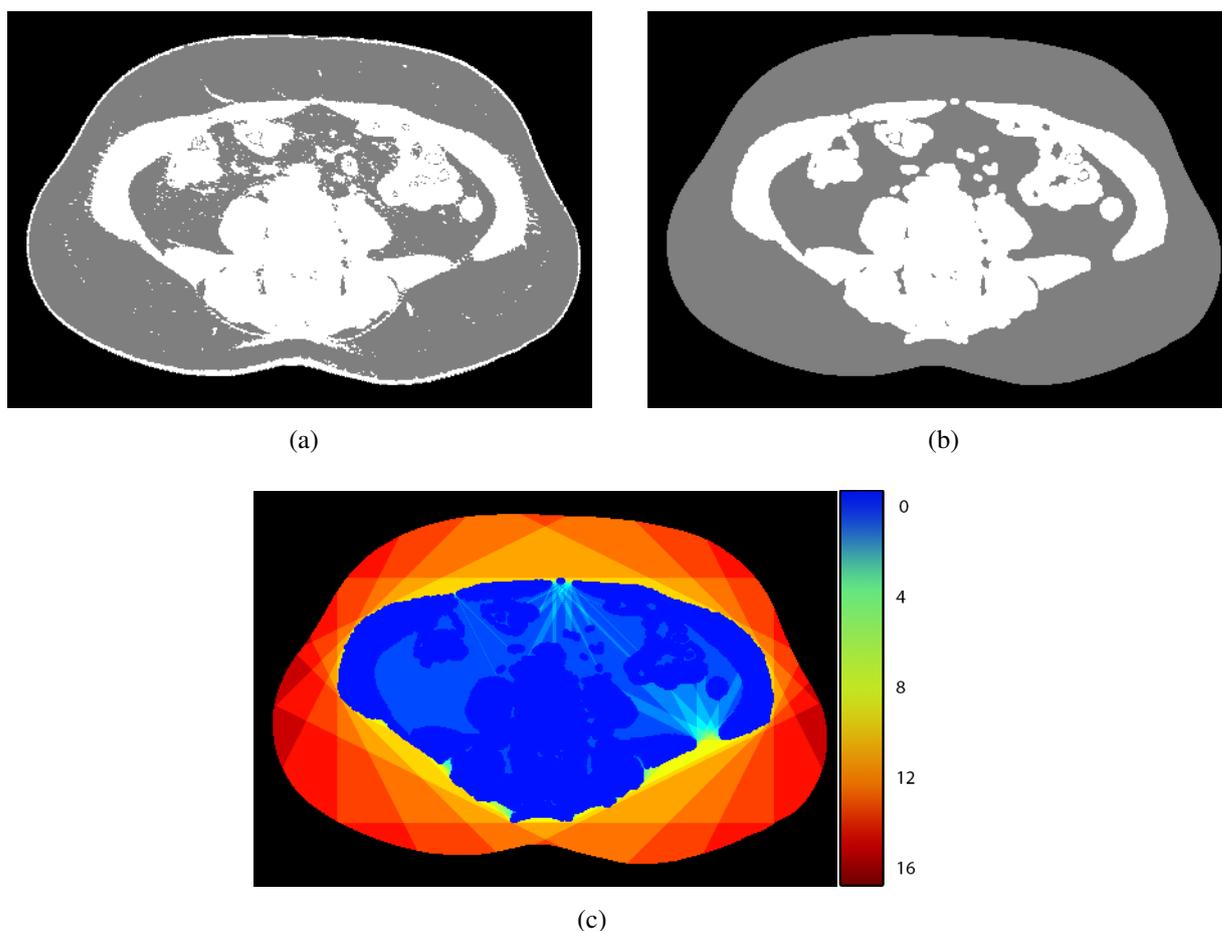


Figura 4.9: Imagens do abdômen. a) Imagem resultante da aplicação do MMFG; b) Imagem resultante da remoção da pele e pequenos objetos; c) Resultado da etapa de classificação dos voxels de acordo com sua posição. Os mapas de cores mostram os valores da matriz acumuladora.

Por fim, com o objetivo de segmentar as regiões de interesse (a região delimitada pela fásia na coxa e a região visceral no abdômen), uma etapa de classificação dos voxels de acordo com sua posição é realizada. Para isso, uma matriz acumuladora com a mesma dimensão da imagem original é criada. Para cada voxel rotulado como gordura (valor 1), percorre-se todos os voxels

posicionados ao longo de linhas digitais (como explicadas na subseção 2.4) em 16 orientações espaçadas com $22,5^\circ$ de angulação no intervalo de $[0^\circ; 360^\circ]$ em 2D e em 80 orientações em 3D com ângulo de azimute de $22,5^\circ$ no intervalo de $[0^\circ; 360^\circ]$ (mesma angulação que em 2D) e ângulo de elevação de 30° no intervalo de $[-60^\circ; 60^\circ]$, até que um voxel de gordura (valor 1) seja encontrado. Durante a varredura dos voxels ao longo das linhas digitais, duas condições são verificadas: (i) se um voxel de fundo da imagem (valor 0) for encontrado, o valor da posição daquele voxel na matriz acumuladora é acrescido de uma unidade; e (ii) se um voxel de não gordura (rótulo 2) for encontrado, nada ocorre na matriz acumuladora. Como saída, é gerada uma imagem que contém seus voxels classificados em relação a sua localização (2D e 3D), conforme mostram as Figuras 4.8 (c) e 4.9 (c).

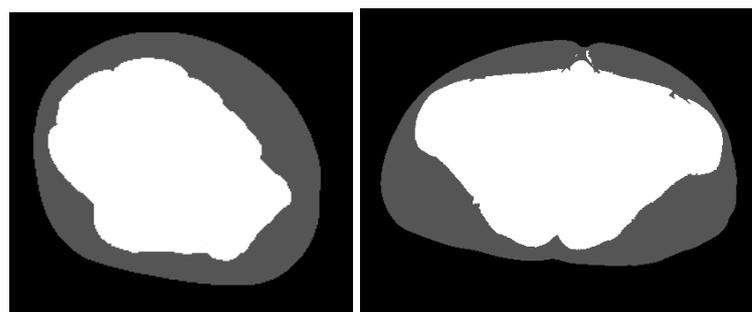
4.5 Pós-processamento

A etapa de pós-processamento tem por objetivo segmentar a região delimitada pela fásia na coxa e na região visceral no abdômen.

4.5.1 Segmentação das regiões de interesse

O pós-processamento aplicado às imagens de TC da coxa e do abdômen busca determinar o valor do limiar T_l que, quando aplicado à matriz acumuladora obtida da técnica das linhas digitais, permita a obtenção da região delimitada pela fásia nas imagens. O valor de T_l foi variado de 1 até N em passos de 1 sendo N a quantidade de linhas digitais projetadas. Quando o processamento é aplicado em duas dimensões, o valor de N é 16 e para três dimensões, N é igual a 80.

Para cada valor de T_l , os valores médios de DSC foram calculados para o TA-Intermuscular utilizando a marcação do especialista como referência e o valor de T_l com maior DSC foi escolhido. As Figuras 4.10 (a) e 4.10 (b) mostram exemplos da segmentação da região de interesse usando o melhor valor experimentalmente determinado para T_l .



(b)

(b)

Figura 4.10: Máscaras binárias obtidas para a segmentação das regiões de interesse; (a) região delimitada pela fáscia na coxa e (b) região visceral no abdômen.

4.6 Forma de análise dos resultados

Para a avaliação dos resultados foi realizada uma comparação entre as máscaras binárias da coxa e abdômen obtidas de maneira automática e as marcações manuais produzidas por um especialista. Para isso, foram calculadas as medidas de similaridade de DSC e os valores de precisão, revocação, ER, F1-score e regressão.

Para a quantificação individual de cada tecido são aplicadas limiarizações utilizando os intervalos de HU da Tabela 2.1. Na coxa, a quantificação do músculo é feita com a contagem dos pixels que estão entre 30 e 100 HU utilizando somente a área sobreposta pela máscara que é delimitada pela fáscia. Utilizando essa mesma máscara, os tecidos TA-Intramuscular e TA-Intermuscular também são quantificados. Nesse caso, a contagem dos pixels é realizada usando os intervalos de 0 a 29 HU para o TA-Intramuscular e -190 a -30 HU para o TA-Intermuscular. Por fim, para a quantificação do TAS, é utilizada a área de sobreposição obtida pela máscara do pré-processamento (M_p) subtraída da máscara que delimita a região da fáscia (M_f): $(M_p - M_f)$ e a contagem de pixels é realizada para as intensidades que estão no intervalo de -190 a -30 HU.

No abdômen, a quantificação do TAS e o TAV é feita de maneira similar à coxa. O intervalo de HU referente a gordura (de -190 a -30 HU) é aplicado para segmentar o TAV e a sua quantificação é realizada contando-se os pixels que estão nesse intervalo utilizando a área sobreposta a região visceral. E o TAS utilizando a área de sobreposição obtida pela máscara do pré-processamento subtraída da máscara que delimita a região visceral usando o mesmo

intervalo de HU.

4.7 Considerações finais

Este capítulo apresentou algumas informações importantes sobre as bases de dados usadas nesta pesquisa, além de descrever a metodologia empregada nas etapas de pré-processamento, processamento e pós-processamento das imagens de TC da coxa e abdômen, e as métricas empregadas na análise dos resultados. No capítulo seguinte são apresentados os resultados obtidos nesta pesquisa.

Capítulo 5

RESULTADOS E DISCUSSÕES

Este capítulo apresenta e discute os resultados obtidos da aplicação da técnica desenvolvida para a segmentação automática dos tecidos da coxa e abdômen em imagens de TC. As comparações são feitas usando como base as marcações manuais de especialistas.

5.1 Visão geral

Para a avaliação da técnica desenvolvida para a segmentação e quantificação de tecidos em imagens de TC de coxas e abdômens foram usadas, respectivamente, 144 imagens (coxas esquerda e direita de 72 pacientes) e 15 imagens. As imagens utilizadas nesta pesquisa foram fornecidas pelo Hospital Universitário da cidade de São Carlos - SP/BR. A avaliação quantitativa da técnica desenvolvida foi feita usando as seguintes métricas: (a) DSC, (b) Precisão, (c) Revocação, (d) F1-score e (e) ER. Essas métricas são calculadas a partir de duas imagens, sendo que a primeira contém a marcação manual feita por um especialista e a segunda contém as marcações obtidas automaticamente pelo método desenvolvido.

5.2 Pré-processamento

Todas as imagens de TC foram pré-processadas para a obtenção das máscaras que delimitam as coxas e o abdômen e são descritas a seguir. Os resultados do pré-processamento foram analisados de maneira visual e quantitativa.

5.2.1 Detecção da coxa

A Figura 5.1 exibe dois exemplos da segmentação de imagens de coxas obtidas após a etapa de pré-processamento. Observando-se o delineamento na cor verde para a coxa esquerda e azul para direita (imagens (b) e (d)), nota-se que o método conseguiu uma boa delimitar para cada coxa.

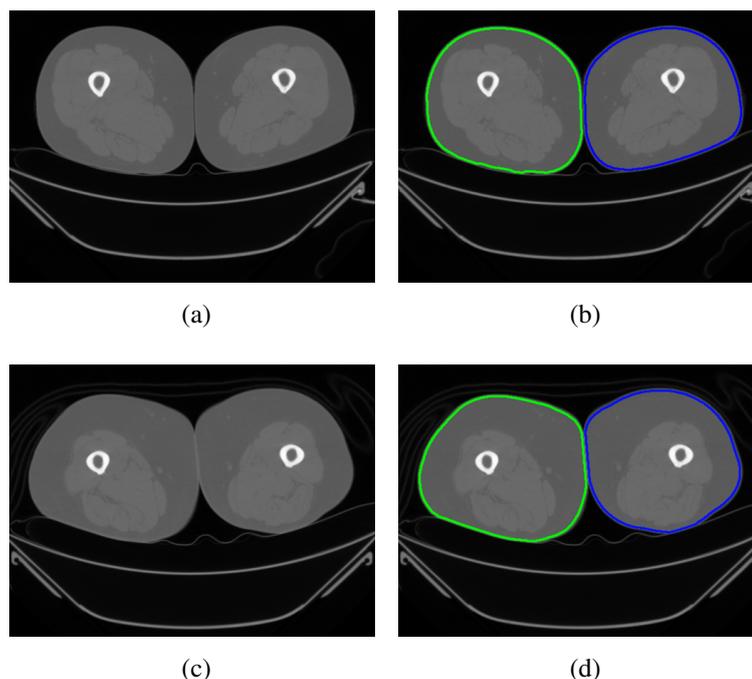


Figura 5.1: A coluna à esquerda representa as imagens originais e a coluna da direita é a representação visual do delineamento (cor verde para a coxa esquerda e azul para direita) gerado pela etapa de pré-processamento sobreposta à imagem original.

Além da inspeção visual, realizou-se a análise quantitativa para as máscaras binárias geradas automaticamente para as coxas e os resultados são apresentados na Tabela 5.1. Os resultados correspondem aos valores médios das métricas obtidos da comparação entre as máscaras binárias, geradas automaticamente, e as obtidas a partir da marcação manual do especialista. Os resultados foram considerados bastante satisfatórios, uma vez que os valores obtidos para as medidas de precisão, revocação e F1-score para a região da coxa foram iguais a 0,99, 0,97 e 0,98, respectivamente.

Métrica	Coxas
Precisão	$0,99 \pm 0,002$
Revocação	$0,97 \pm 0,008$
F ₁ – score	$0,98 \pm 0,003$
DSC	$0,98 \pm 0,003$
ER	$0,02 \pm 0,007$

Tabela 5.1: Avaliação quantitativa obtida para a comparação entre as máscaras binárias determinadas automaticamente e manualmente para a coxa na etapa de pré-processamento.

A partir das análises visuais e quantitativas pode-se concluir que a etapa de pré-processamento para a coxa obteve resultados muito semelhantes aos obtidos pelos especialistas.

5.2.2 Detecção do abdômen

A Figura 5.2 exibe dois exemplos da segmentação do abdômen obtidas da etapa de pré-processamento. Observando-se o delineamento na cor verde (imagens (b) e (d)), nota-se que o método conseguiu delimitar com precisão o abdômen.

Da mesma forma que para a coxa, no abdômen, a análise quantitativa da geração automática das máscaras binárias foi feita após a inspeção visual e os resultados são apresentados na Tabela 5.2. Tais resultados correspondem aos valores médios das métricas obtidos da comparação entre as máscaras binárias, geradas automaticamente, e as obtidas a partir da marcação manual do especialista. Neste caso, os resultados também foram considerados bastante satisfatórios, uma vez que, as medidas de precisão, revocação e F1 foram iguais a 0,99, 0,97 e 0,98, respectivamente, diferenciando dos resultados das coxas apenas no desvio padrão.

Métrica	Abdômen
Precisão	$0,99 \pm 0,004$
Revocação	$0,97 \pm 0,012$
F ₁ – score	$0,98 \pm 0,008$
DSC	$0,98 \pm 0,008$
ER	$0,02 \pm 0,015$

Tabela 5.2: Avaliação quantitativa obtida da comparação entre as máscaras binárias geradas automaticamente e manualmente para o abdômen na etapa de pré-processamento.

A partir das análises visuais e quantitativas pode-se concluir que a etapa de pré-processamento para o abdômen também gerou resultados muito semelhantes aos dos especialistas. É impor-

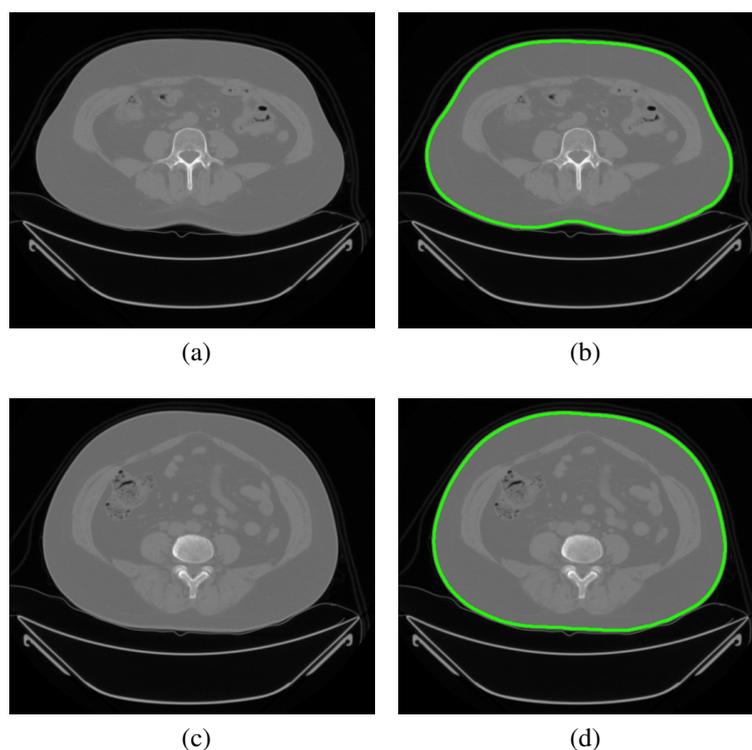


Figura 5.2: A coluna à esquerda representa as imagens originais e a coluna da direita é a representação visual do delineamento (cor verde) gerado pela etapa de pré-processamento sobreposta à imagem original.

tante ressaltar que as etapas de pré-processamento da coxa e do abdômen, embora tenham gerado resultados semelhantes, são diferentes, conforme descrito no Capítulo 4 seção 4.3.

5.3 Segmentação das regiões de interesse

A segmentação das regiões de interesse tem por objetivo segmentar a região delimitada pela fáscia na coxa e na região visceral do abdômen usando a técnica de linhas digitais.

5.3.1 Linhas digitais

Conforme descrito no Capítulo 4 seção 4.4, na técnica de linhas digitais, um contador é atribuído a cada pixel da imagem e tem por objetivo indicar quantas linhas digitais, projetadas a partir de um pixel, conseguiram atingir o *background* antes de atingir um pixel classificado como não gordura. O valor desse contador é usado para definir quais pixels pertencem à região de interesse (região visceral para o abdômen e região delimitada pela fáscia para a coxa).

Foram projetadas linhas digitais considerando duas e três dimensões. Para duas dimensões,

poucas linhas são projetadas (16 linhas) e, portanto, torna-se mais fácil identificar, visualmente, qual limiar deve ser usado, como é o caso das Figuras 5.3a e 5.3c. Por outro lado, para três dimensões, um número elevado de linhas digitais é projetado (80 linhas), o que dificulta a análise visual, conforme é possível observar nas Figuras 5.3b e 5.3d. Portanto, um estudo de parâmetros foi realizado para a escolha do melhor valor de limiar (T_l) utilizado por esse contador. Nesse estudo, para cada valor de T_l foram calculados os valores de DSC para a quantificação do tecido TA-Intermuscular da coxa e do TAV para o abdômen.

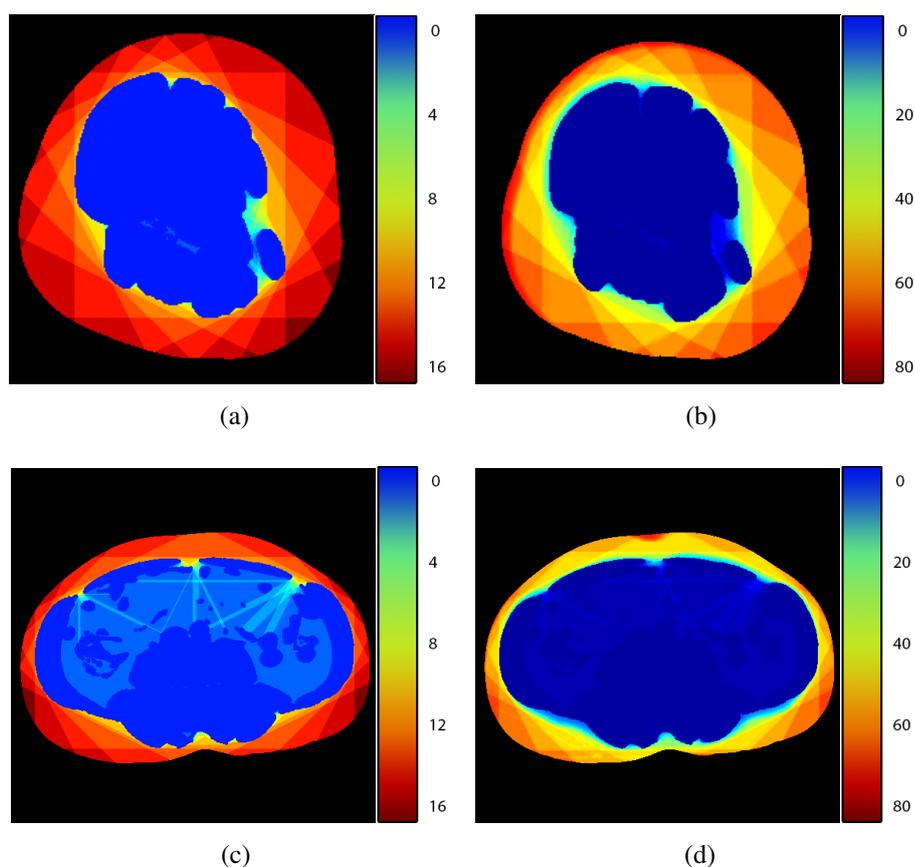


Figura 5.3: Resultado da etapa da projeção das linhas digitais. (a) coxa usando 16 linhas digitais (2D); (b) coxa usando 80 linhas digitais (3D); (c) abdômen usando 16 linhas digitais (2D); e (d) abdômen usando 80 linhas digitais (3D). Os mapas de cores em cada imagem mostram os valores de variação do contador.

Os gráficos representados pelas Figuras 5.4(a) e 5.4(b) representam o comportamento do valor de DSC para cada valor de T_l na quantificação do TA-Intermuscular utilizando as abordagens 2D e 3D, respectivamente. Nas Figuras 5.4(c) e 5.4(d) têm-se os valores de DSC para cada valor de T_l para a quantificação do TAV utilizando as abordagens 2D e 3D, respectivamente. A partir da análise dos gráficos, observa-se que, para o TA-Intermuscular, o maior valor de DSC para a abordagem 3D foi obtido para $T_l = 40$ e para o TAV o maior valor de DSC , para a abordagem 2D, foi para $T_l = 6$.

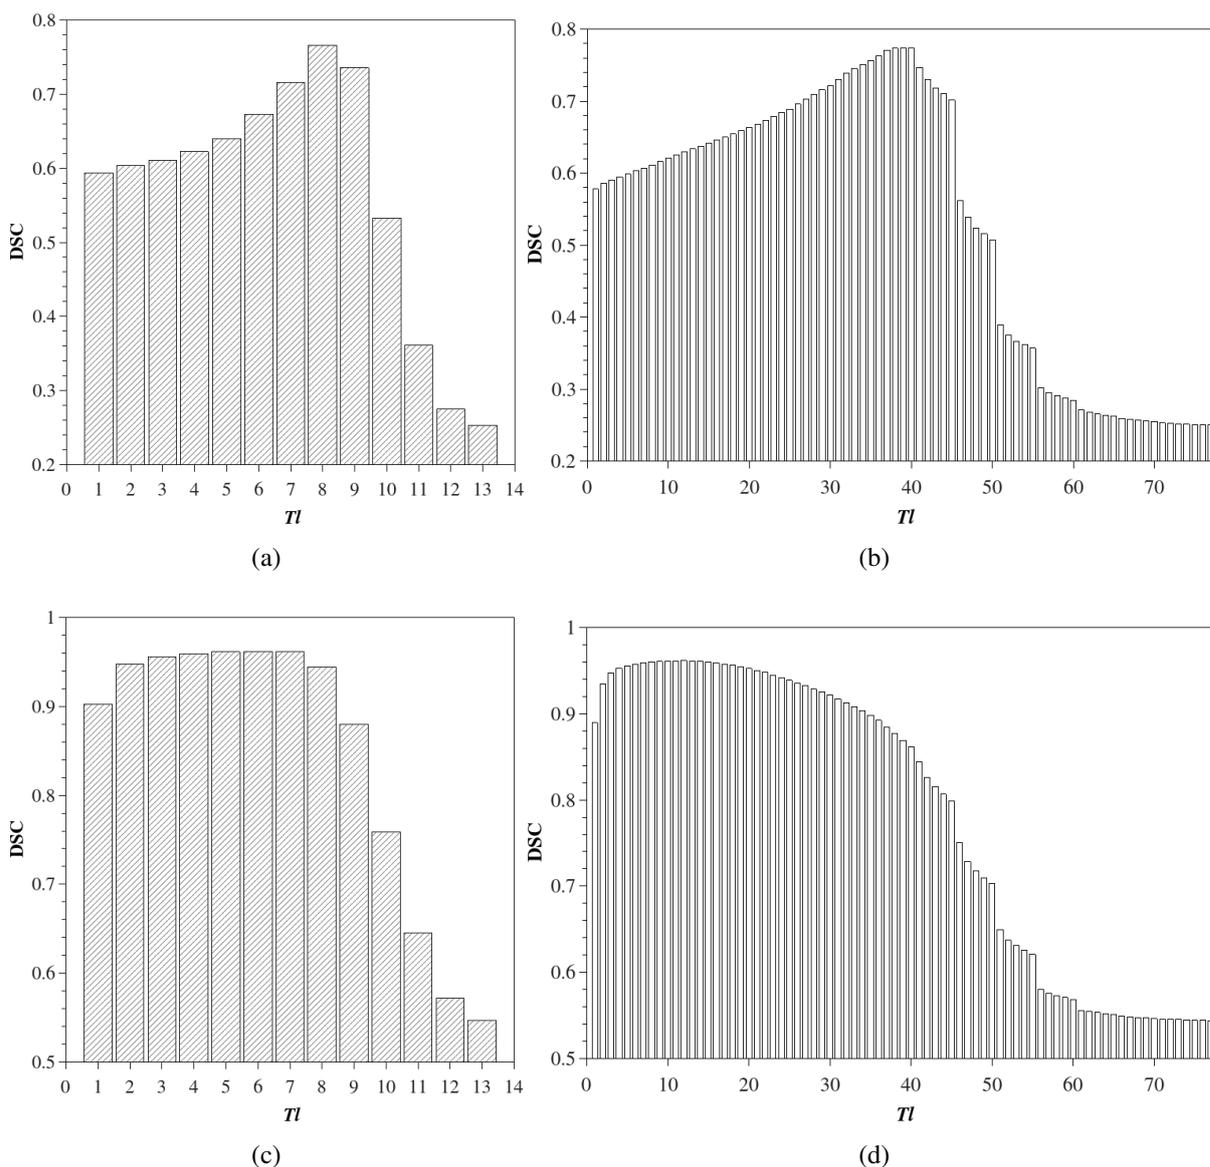


Figura 5.4: Avaliação do parâmetro das linhas digitais (T_l) usando as abordagem 2D e 3D para as coxas (a) e (b) e para o abdômen (c) e (d), respectivamente.

É importante ressaltar que o valor de T_l para o TA-Intermuscular é superior em relação ao TAV tanto em 2D quanto em 3D. Esse fato se justifica pelo fato da gordura visceral estar, em geral, cercada predominantemente por músculos, tornando mais fácil à aplicação da técnica de projeções de linhas digitais em comparação à coxa.

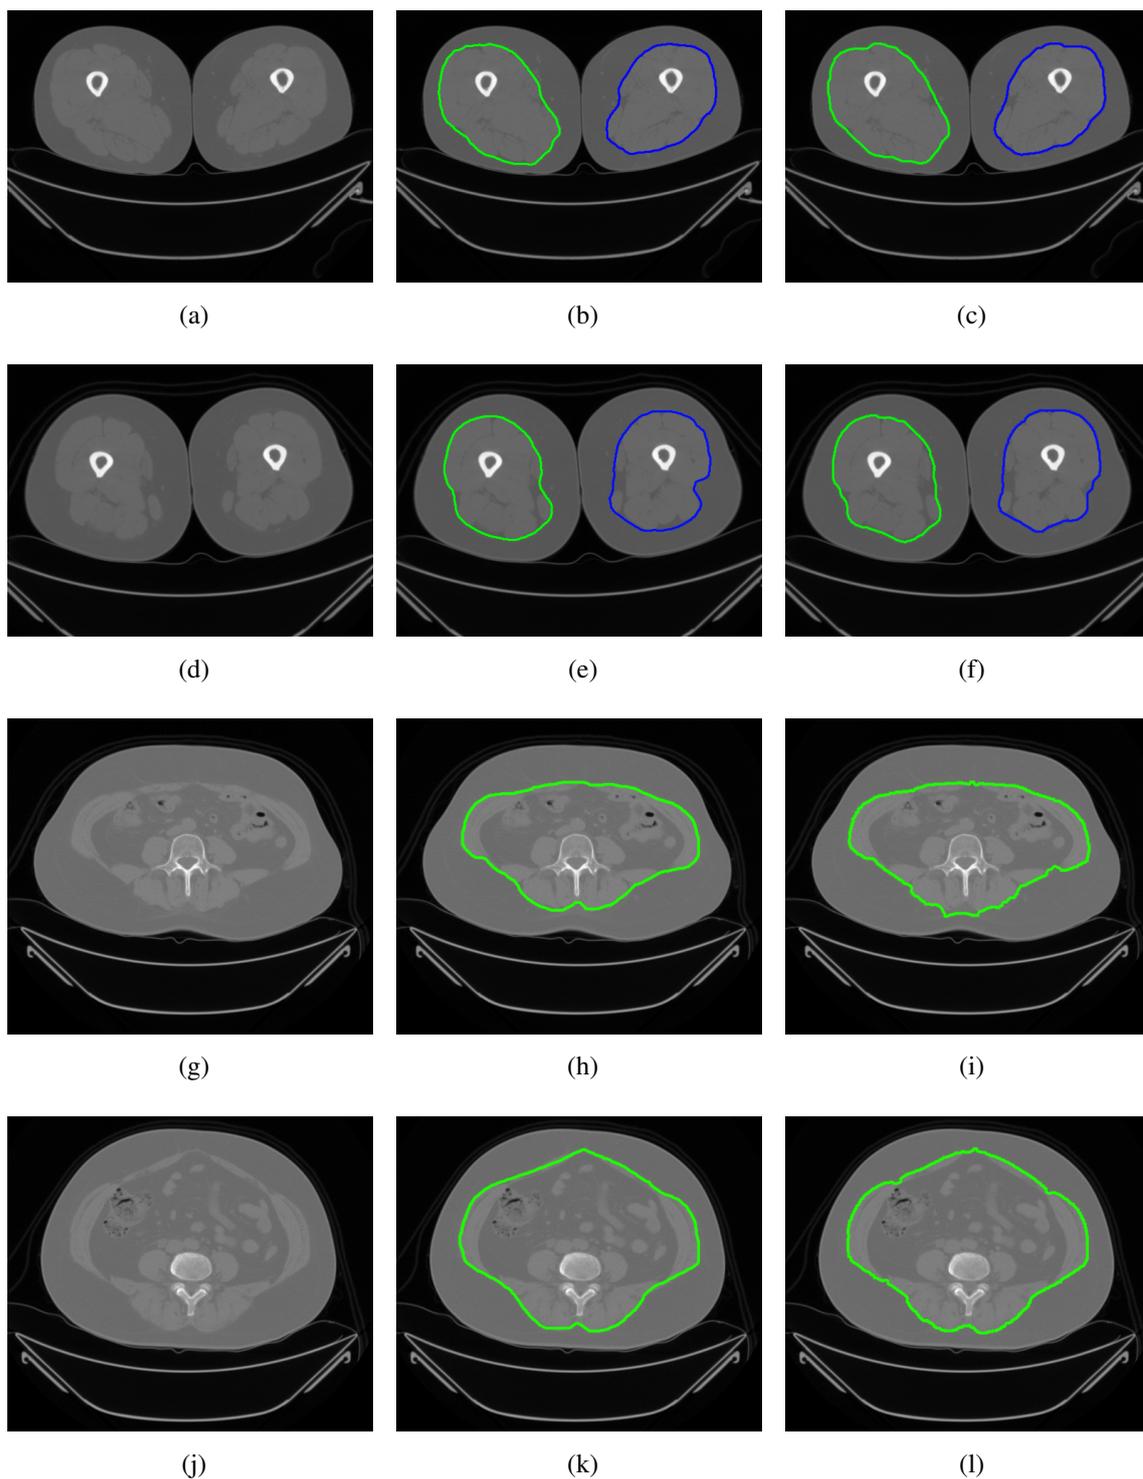


Figura 5.5: Resultado das delimitações obtidas pelos melhores valores de T_l . A coluna da esquerda representa as imagens originais, a coluna central representa as marcações manuais do especialista e a coluna da direita representa as segmentações obtidas automaticamente pelos melhores valores de T_l . A representação visual do delineamento é mostrada na cor verde para a coxa esquerda e azul para direita; e verde para a região visceral.

Nos gráficos da Figura 5.4(c) e 5.4(d) usados para relatar a quantificação do TAV, é pos-

sível notar que valores baixos de T_l já conseguem bons resultados, com métricas de DSC geralmente maiores que 0,9, o que não se repete para os resultados obtidos da quantificação do TA-Intermuscular. Uma possível explicação para o comportamento desse parâmetro pode ser dada pelo fato de que pequenos valores de T_l implicam em poucas linhas que alcançaram o fundo da imagem sem entrar em contato com outro tipo de tecido e, conforme mencionado anteriormente, o TAV se encontra cercado predominantemente por músculos. Portanto, o uso de pequenos valores de T_l já é suficiente para a obtenção de resultados satisfatórios.

Por fim, em ambos casos, os valores de quantificações dos tecidos são baixos quando os valores de T_l são altos, pois com elevados valores de T_l , a região delimitada se torna a região total da coxa ou do abdômen, fazendo com que os tecidos sejam quantificados incorretamente. A Figura 5.5 mostra exemplos de imagens de coxas e abdômens (primeira coluna) com as regiões de interesse delimitadas por um especialista (segunda coluna) e utilizando os valores de T_l escolhidos via análise dos gráficos 5.4 (terceira coluna). Os exemplos de segmentação das imagens das coxas obtidas para valor de $T_l = 40$ e abordagem 3D são ilustradas nas imagens 5.5(c) e 5.5(f), e abdômens para valor de $T_l = 6$ e abordagem 2D pelas imagens 5.5(i) e 5.5(l).

5.3.2 Região delimitada pela fáschia

A máscara da região delimitada pela fáschia é obtida automaticamente após a definição e aplicação do limiar T_l . A Tabela 5.3 mostra os resultados da comparação entre a máscara da região da fáschia gerada automaticamente e a máscara obtida pelas marcações dos especialistas utilizando as abordagens 2D e 3D, respectivamente. Os maiores resultados são destacados em negrito. Tanto para o 2D quanto para o 3D, foram obtidos resultados considerados satisfatórios, uma vez que, as melhores medidas de precisão, revocação, F1 e DSC foram próximos de 0,98 e erro relativo de 0,04.

Métrica	Fáschia 2D	Fáschia 3D
Precisão	0,982 ± 0,010	0,974 ± 0,019
Revocação	0,975 ± 0,016	0,983 ± 0,011
F ₁ – score	0,979 ± 0,009	0,979 ± 0,010
DSC	0,979 ± 0,009	0,979 ± 0,010
ER	0,04 ± 0,017	0,04 ± 0,021

Tabela 5.3: Avaliação quantitativa obtida da comparação entre as máscaras binárias determinadas automaticamente e manualmente para a região delimitada pela fáschia. Os resultados das métricas são apresentados com a média ± desvio padrão, usando todas as imagens da base de dados.

5.3.2.1 Quantificação dos tecidos da coxa

Para a quantificação dos tecidos da coxa, duas máscaras são necessárias: a máscara da coxa, obtida automaticamente na etapa de pré-processamento, e a máscara da região delimitada pela fásia, obtida no final da aplicação da técnica de linhas digitais. A partir de tais máscaras a quantificação dos tecidos é realizada, levando-se em consideração os intervalos de HU de cada tecido (explicitados no Capítulo 2 Tabela 2.1) e são comparadas com as máscaras demarcadas pelo especialista (*ground-truth*).

Os resultados descritos na Tabela 5.4 mostram que, para todos os tecidos da coxa aplicando a técnica proposta em 3D, as métricas de precisão, revocação, F1 e DSC foram elevados. É possível notar também, que o melhor resultado foi obtido para o músculo, com valores iguais a 0,99 para todas as medidas e com ER de apenas 0,001. Tal resultado pode ser explicado pelo fato do músculo ser um dos tecidos com maior contraste em relação aos demais existentes nas imagens de TC da coxa, logo pode-se dizer que é um dos mais fáceis de se quantificar. Por outro lado, o pior resultado foi obtido para o TA-Intermuscular, com precisão de 0,76, revocação de 0,81 e F1 e DSC iguais a 0,78. Uma explicação para esse resultado é o fato do TA-Intermuscular encontrar-se no mesmo intervalo de HU que o TAS, porém com uma quantidade muito inferior em relação ao TAS. Neste caso, mesmo se o erro na detecção da região delimitada pela fásia for pequeno, este pode gerar métricas com valores muito mais baixos para o tecido. A Figura 5.6 ilustra um exemplo em que a fásia foi detectada erroneamente, o que contribuiu diretamente para os números baixos em relação a quantificação do TA-Intermuscular.

Tipos de Tecido	Precisão	Revocação	F ₁ – score	DSC	ER
TAS	0,99 ± 0,01	0,95 ± 0,01	0,97 ± 0,01	0,97 ± 0,01	0,05 ± 0,01
TA-Intramuscular	0,99 ± 0,01	0,99 ± 0,01	0,99 ± 0,01	0,99 ± 0,01	0,01 ± 0,01
TA-Intermuscular	0,76 ± 0,03	0,81 ± 0,12	0,78 ± 0,08	0,78 ± 0,08	0,47 ± 0,13
Músculo	0,999 ± 0,001	0,999 ± 0,001	0,99 ± 0,01	0,999 ± 0,001	0,001 ± 0,001

Tabela 5.4: Avaliação quantitativa para a quantificação de todos os tecidos da coxa em imagens de TC aplicando a técnica proposta 3D.

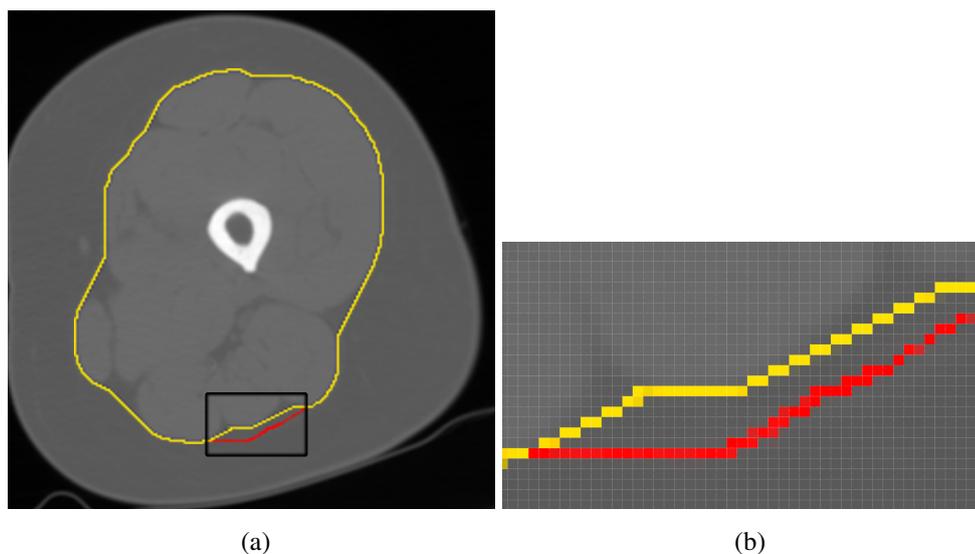


Figura 5.6: Imagem de TC com (a) borda da fáscia detectada utilizando o método automático (amarelo) e marcação manual produzida por um especialista (vermelho); (b) Zoom da imagem para ilustrar uma discordância entre o contorno manual e automático.

A Tabela 5.5 mostra os resultados obtidos usando a técnica de linhas digitais aplicada para o caso 2D. Apesar dos valores de DSC e F1 serem um pouco maiores que os obtidos pela técnica 3D, o desvio padrão também aumenta, portanto, ao comparar as duas Tabelas 5.5 e 5.4 conclui-se que os resultados obtidos pelas técnicas 2D e 3D são semelhantes.

Tipos de Tecido	Precisão	Revocação	F_1 – score	DSC	ER
TAS	$0,99 \pm 0,01$	$0,97 \pm 0,01$	$0,98 \pm 0,01$	$0,98 \pm 0,01$	$0,03 \pm 0,02$
TA-Intramuscular	$0,99 \pm 0,01$	$0,99 \pm 0,01$	$0,99 \pm 0,01$	$0,99 \pm 0,01$	$0,01 \pm 0,01$
TA-Intermuscular	$0,81 \pm 0,10$	$0,74 \pm 0,11$	$0,76 \pm 0,06$	$0,76 \pm 0,06$	$0,45 \pm 0,12$
Músculo	$0,999 \pm 0,001$	$0,999 \pm 0,001$	$0,99 \pm 0,001$	$0,999 \pm 0,001$	$0,001 \pm 0,001$

Tabela 5.5: Avaliação quantitativa para a quantificação de todos os tecidos da coxa em imagens de TC aplicando a técnica proposta 2D.

A Figura 5.7 mostra os gráficos de dispersão, juntamente com a análise de regressão linear, da quantificação (em pixels) do TAS, músculo, TA-Intermuscular e TA-Intramuscular resultantes da segmentação manual e automática. Como pode-se observar, os coeficientes de correlação (R) entre as segmentações manuais e automáticas são próximos de 1, demonstrando que os resultados da técnica proposta se aproximaram significativamente das medidas realizadas pelo especialista. Pode-se notar que o coeficiente de correlação de *Pearson* é sempre maior no TAS,

músculo e TA-Intramuscular do que no TA-Intermuscular. Isso se deve principalmente ao fato de que o TAS, músculo e TA-Intramuscular serem mais abundantes que o TA-Intermuscular, com valores máximos de quantificação, respectivamente, iguais a 25000, 30000, 9000 e 4000 pixels. Logo, pequenos erros na quantificação dos pixels do TA-Intermuscular incidem em erros percentuais muito maiores que os demais tecidos.

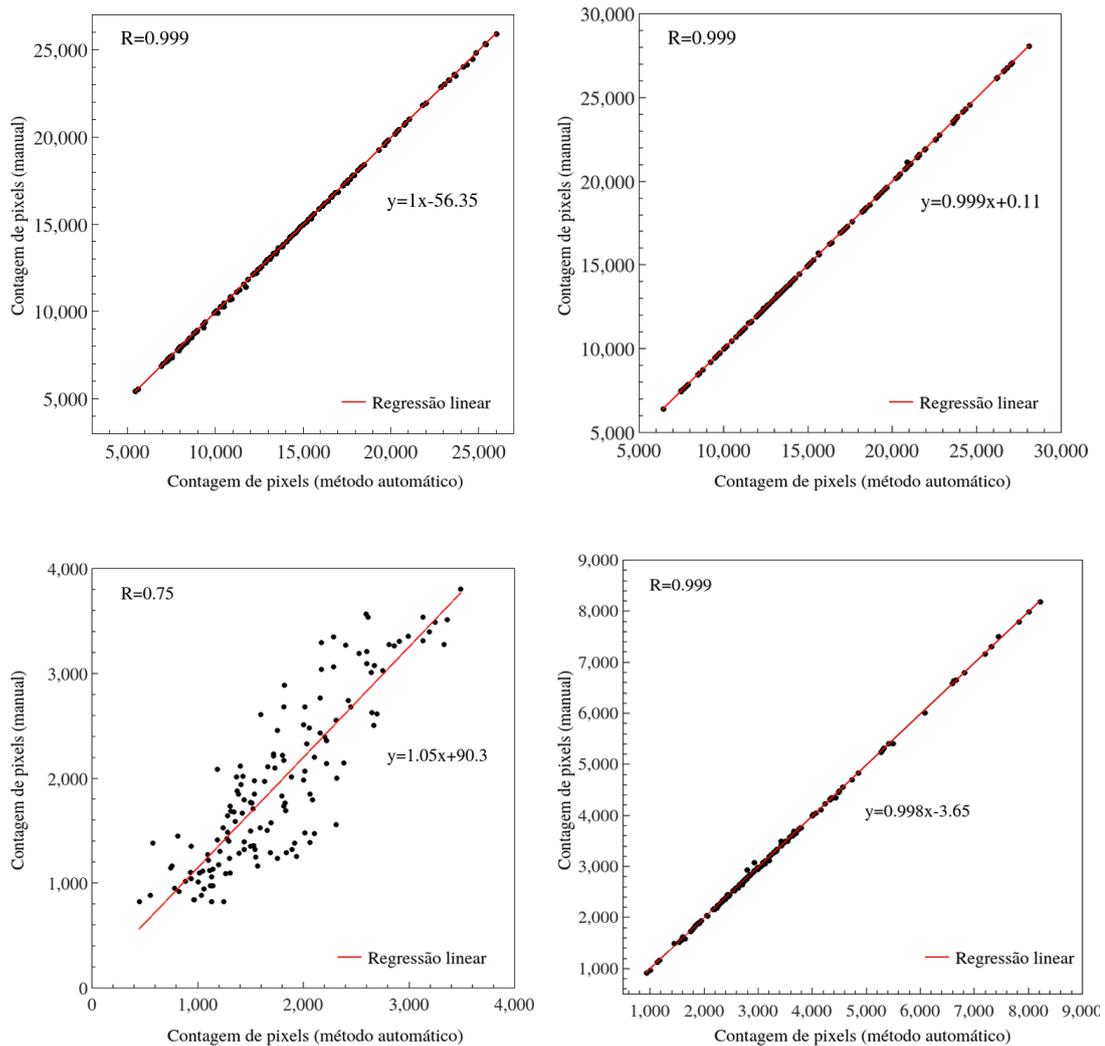


Figura 5.7: Análises de correlação para os tecidos da coxa calculados de forma manual e automática. (a) TAS; (b) músculo; (c) TA-Intermuscular e; (d) TA-Intramuscular.

5.3.3 Região visceral

A máscara da região visceral também é obtida automaticamente após a definição e aplicação do limiar T_l . A Tabela 5.6 mostra os resultados da comparação entre a máscara da região

visceral gerada automaticamente e máscara obtida pelas marcações dos especialistas utilizando as abordagens 2D e 3D, respectivamente. Os melhores resultados são destacados em negrito. Tanto para o 2D quanto para o 3D, foram obtidos resultados considerados satisfatórios, uma vez que, as melhores medidas de precisão, revocação, F1, DSC e ER foram 0,98, 0,99, 0,98, 0,98 e 0,04, respectivamente.

Métrica	Visceral 2D	Visceral 3D
Precisão	0,976 ± 0,013	0,977 ± 0,010
Revocação	0,988 ± 0,006	0,985 ± 0,007
F ₁ – score	0,982 ± 0,006	0,981 ± 0,005
DSC	0,982 ± 0,006	0,981 ± 0,005
ER	0,036 ± 0,013	0,037 ± 0,011

Tabela 5.6: Avaliação quantitativa obtida da comparação entre as máscaras binárias determinadas automaticamente e manualmente para a região visceral. Os resultados das métricas são apresentados com a média ± desvio padrão, usando todas as imagens da base de dados.

5.3.3.1 Quantificação dos tecidos do abdômen

Para a quantificação dos tecidos do abdômen, duas máscaras são necessárias: a máscara do abdômen, obtida automaticamente ao final da etapa de pré-processamento, e a máscara da região visceral, obtida no final da aplicação da técnica de linhas digitais. A partir de tais máscaras, em conjunto com os valores de intervalo de HU de cada tecido (explicitados no Capítulo 2 - Tabela 2.1), a quantificação dos tecidos é feita. Conforme citado no Capítulo 2 seção 2.2, não é possível fazer a quantificação de todos os tecidos do abdômen. Porém, o principal objetivo desse projeto de pesquisa, de separar os tecidos das gorduras existentes na região, foi concluído e os resultados são apresentados nas Tabelas 5.7 e 5.8.

Apesar de não ser possível a quantificação de todos os tecidos do abdômen, os resultados descritos na Tabela 5.7 mostram que para os tecidos quantificados, as métricas de precisão, revocação, F1 e DSC foram elevadas e superiores aos obtidos pela coxa. É possível notar também, que todas as métricas possuem valores acima de 0,97 e erro relativo de 0,03 para TAS, e valores acima de 0,95 com erro relativo de 0,07 para TAV. Embora, na região abdominal, exista um problema semelhante ao descrito na coxa, conforme exemplificado na Figura 5.8, os valores continuam elevados. Isso ocorre pois o TAV, em geral, possui contagem de pixels próxima ao TAS, diferente da coxa, em que o TAS possui quantidades muito maiores que o TA-Intermuscular. Logo, ao contrário do que acontece com a imagem da coxa, pequenos erros na segmentação do abdômen não afetam consideravelmente os valores obtidos.

Tipos de Tecido	Precisão	Revocação	F ₁ – score	DSC	ER
TAS	0,99 ± 0,01	0,97 ± 0,01	0,98 ± 0,01	0,98 ± 0,01	0,03 ± 0,01
TAV	0,95 ± 0,03	0,97 ± 0,02	0,96 ± 0,02	0,96 ± 0,02	0,07 ± 0,04

Tabela 5.7: Avaliação quantitativa para a quantificação de todos os tecidos da coxa em imagens de TC aplicando a técnica proposta 2D.

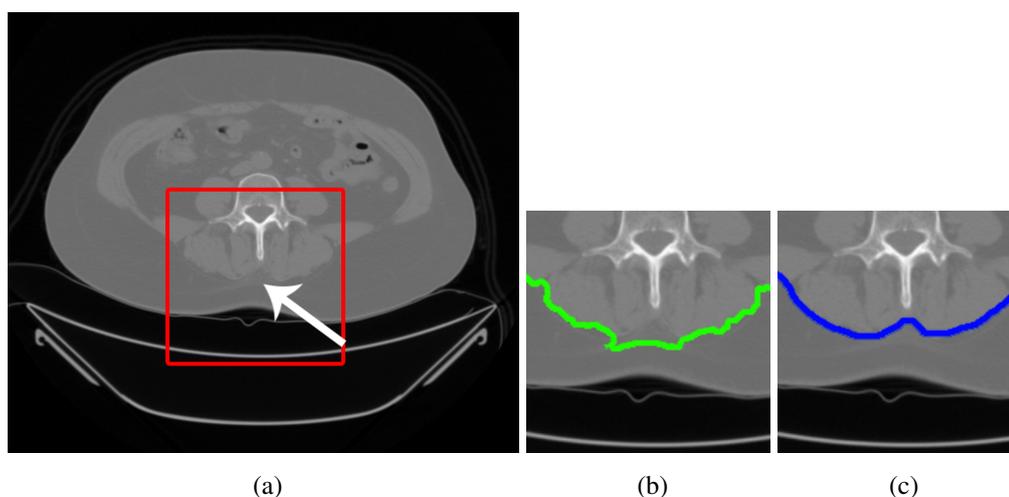


Figura 5.8: Imagem de TC do abdômen (a) original; (b) borda da região visceral detectada utilizando o método automático (contorno verde); e (c) marcação manual produzida por um especialista (contorno azul).

A Figura 5.8 ilustra um caso em que a região visceral detectada automaticamente (5.8(b)) difere significativamente da região manualmente anotada pelo especialista (5.8(c)). Ao longo das imagens do abdômen processadas, problemas dessa natureza ocorreram somente uma vez, porém, como a base de dados possui um número pequeno de imagens (apenas 15 imagens) não é possível afirmar que este não seja um erro recorrente. A fim de descobrir a origem do problema, todos os passos do algoritmo foram verificados e descobriu-se que esse erro ocorreu na etapa de processamento, mais precisamente na segmentação inicial dos tecidos usando a técnica MMFG. Uma explicação para o insucesso do MMFG para essa imagem é o fato da região (seta branca na imagem 5.8 (a)) possuir muitos voxels de intensidade de HU muito próximos de músculo ao invés de gordura, o que não ocorre nos outros casos.

A Tabela 5.7 apresenta os resultados obtidos usando a técnica de linhas digitais aplicada para o caso 3D. Nota-se que os resultados para a quantificação de TAS e TAV são muito seme-

lhantes ao 2D, com diferenças ainda menores que as da coxa. Entretanto, pelo fato da análise ter sido realizada usando apenas 15 imagens de TC, fica difícil, a partir destes resultados, concluir que o processamento 3D não apresenta vantagens em relação ao processamento 2D. Porém, mesmo com poucas imagens, os resultados obtidos foram elevados. Todos os resultados obtidos para DSC, precisão, revocação e F1-score foram superiores a 0,95 e os ER menores que 0,07. Logo, embora a justificativa para o uso da técnica 3D seja difícil de ser provada, a técnica de projeção de linhas digitais 3D mostrou um excelente desempenho para a segmentação das gorduras no abdômen.

Tipos de Tecido	Precisão	Revocação	F ₁ – score	DSC	ER
TAS	0,99 ± 0,01	0,97 ± 0,01	0,98 ± 0,01	0,98 ± 0,01	0,03 ± 0,01
TAV	0,95 ± 0,03	0,97 ± 0,01	0,96 ± 0,02	0,96 ± 0,02	0,07 ± 0,03

Tabela 5.8: Avaliação quantitativa para a quantificação de todos os tecidos da coxa em imagens de TC aplicando a técnica proposta 3D.

A Figura 5.9 apresenta os gráficos de dispersão da quantificação (em pixels) do TAS e TAV resultantes da segmentação manual e automática, com as correspondentes análises de regressão linear. Como pode-se observar, os coeficientes de correlação (R) entre as segmentações manuais e automáticas são próximos de 1, demonstrando que os resultados da técnica proposta se aproximaram significativamente das medidas realizadas pelo especialista. Pode-se notar ainda que o coeficiente de correlação de *Pearson* é maior no TAS do que no TAV, mas mesmo assim, ambos possuem valores muito próximos.

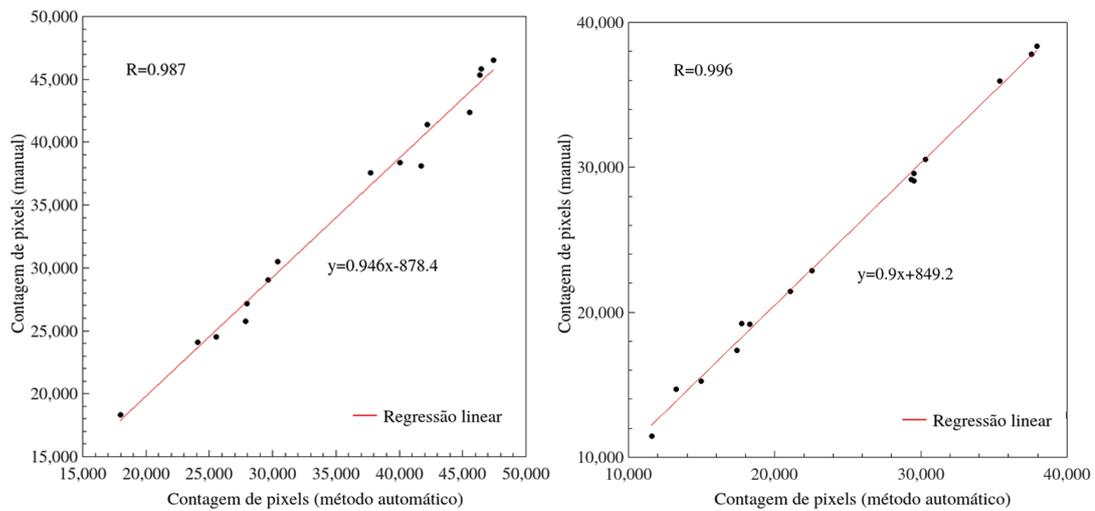


Figura 5.9: Análises de correlação para os tecidos da coxa calculados de forma manual e automática. (a) TAS e; (b) TAV.

5.4 Variabilidade entre os especialistas

Uma análise das marcações dos especialistas e do método automático desenvolvido nessa pesquisa foi realizada em 38 imagens de TC da coxa (19 esquerdas e 19 direitas). As marcações manuais dos especialistas foram utilizadas para comparação com o método automático, além de permitir calcular a variabilidade de marcações entre os especialistas. Nessa análise, seis marcações manuais distintas foram feitas por imagem, em que três especialistas demarcaram duas imagens em dias distintos, com um intervalo de pelo menos uma semana. Para a análise, o TA-Intermuscular foi utilizado por ser o tecido mais difícil de quantificar. Os resultados desta análise são graficamente mostrados na Figura 5.10. Os pontos pretos são usados para indicar os valores médios das anotações manuais com seus respectivos desvios padrão, e os pontos vermelhos mostram os resultados do método de segmentação automática.

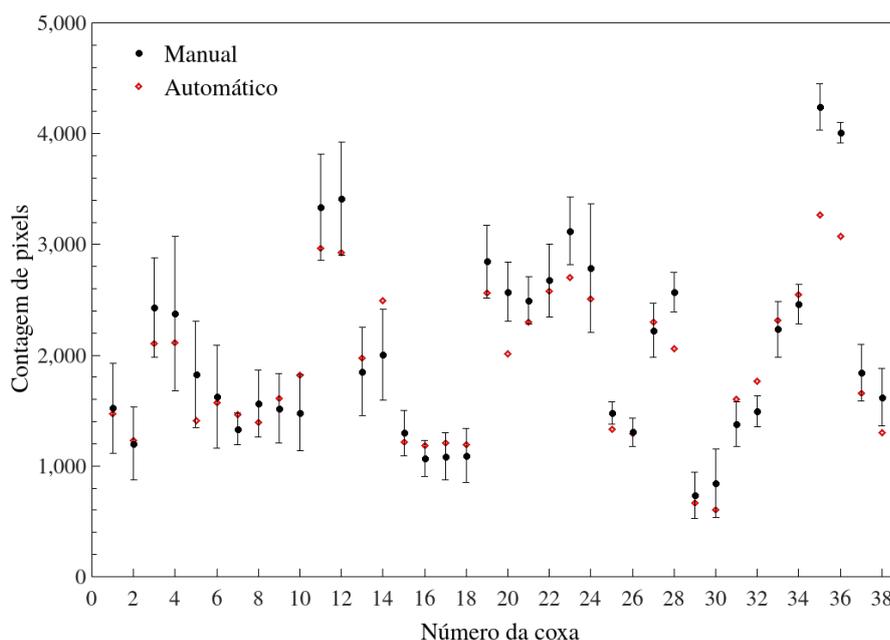


Figura 5.10: Resultados médios e desvio padrão (em preto) obtidos de seis marcações manuais (três especialistas com duas marcações cada um) comparado com o método automática (ponto em vermelho) para a quantificação do TA-Intermuscular.

Analisando os resultados da Figura 5.10, pode-se notar uma alta variabilidade entre as marcações dos especialistas, principalmente para as coxas de números 4, 11, 12 e 24. Também é possível verificar que, exceto em nove coxas, os resultados do método automático estão dentro do desvio padrão. Nos nove casos em que a abordagem automática se desviou dos especialistas, identificamos o mesmo tipo de problema, conforme indicado na Figura 5.6. Esse fato deve-se principalmente à dificuldade em determinar a localização da fáscia nas imagens TC. Embora os resultados da quantificação TA-Intermuscular sejam menores do que os outros tecidos, o problema é minimizado ao considerar a alta variabilidade entre os especialistas em suas marcações manuais.

5.5 Considerações Finais

Este capítulo apresentou e discutiu os resultados obtidos utilizando a abordagem desenvolvida durante este trabalho de Mestrado. Foram apresentados os resultados das etapas de pré-processamento das imagens, da segmentação das regiões de interesse (região delimitada pela fáscia na coxa e região visceral no abdômen) e das variações que ocorrem entre as marcações manuais, feitas por especialistas. Os resultados mostraram que: (i) tecidos adiposos da coxa são mais difíceis de quantificar do que os do abdômen; (ii) ambas quantificações obtiveram bons resultados em relação às métricas estatísticas utilizadas; (iii) as abordagens 2D e 3D

apresentaram resultados semelhantes e; (iv) as marcações manuais produzidas por especialistas estão sujeitas à grandes variações, reafirmando a necessidade de um método computacional automático para a quantificações dos tecidos. No capítulo seguinte são apresentadas as conclusões finais deste trabalho.

Capítulo 6

CONCLUSÕES

Este capítulo apresenta as conclusões finais deste trabalho, indicando as principais contribuições, trabalhos submetidos e ideias para trabalhos futuros.

6.1 Conclusões

Este trabalho de mestrado apresentou um modelo computacional automático para a segmentação e a quantificação de tecidos adiposos e musculares em imagens de TC da coxa e do abdômen. A motivação por trás dessa pesquisa está na importância clínica da quantificação dos TA, que ajuda a prever a ocorrência de diabetes tipo 2 e osteoartrite, entre outras síndromes metabólicas e doenças reumáticas. Apesar da simplicidade do método apresentado, os resultados obtidos provaram sua eficácia e mostraram que a quantificação automática de tecidos adiposos da coxa e abdômen em imagens de TC é viável.

A abordagem proposta para alcançar esse objetivo constituiu na segmentação das regiões de interesse usando limiarizações, modelo de misturas, filtros morfológicos e projeção de linhas digitais para classificar cada voxel de gordura em relação a sua posição a outros tecidos. Os resultados obtidos demonstraram que o método proposto foi capaz de quantificar os tecidos tanto da coxa quanto do abdômen com elevados valores de DSC (e outras métricas quantitativas).

Analisando-se individualmente os resultados da coxa, verificou-se que a quantificação do TA-Intermuscular resultou em valores inferiores aos demais. Isso pode ser explicado pelo fato da quantidade do TA-Intermuscular ser muito inferior do que o TAS, fazendo que pequenas diferenças entre as segmentações (manual e automática) resultem em um grande erro percentual.

Por último, analisando-se os resultados do abdômen, verificou-se que todas as métricas utilizadas apresentaram valores elevados. Assim como a fásia na coxa, a segmentação automática

da região visceral é um grande desafio. Porém, neste caso, devido à quantidade de TAS e TAV não ser muito diferente, pequenas diferenças entre as segmentações (manual e automática) não resultam em um grande erro percentual.

6.2 Principais contribuições

As contribuições desse trabalho podem ser resumidas da seguinte forma:

- Desenvolvimento de uma metodologia automática para separar e segmentar as coxas em imagens de TC;
- Desenvolvimento de uma metodologia automática para segmentar o abdômen em imagens de TC;
- Aplicação e comprovação da eficiência do MMFG para segmentar tecidos adiposos em imagens de TC;
- Desenvolvimento de uma metodologia para predição da região delimitada pela fáscia em imagens de TC da coxa e a detecção da região visceral no abdômen utilizando linhas digitais;
- Validação da metodologia proposta usando 144 imagens da coxa e 15 imagens do abdômen.

6.3 Sugestões para trabalhos futuros

Ao longo do desenvolvimento dessa pesquisa, constatou-se uma divergência entre os trabalhos da literatura sobre como os tecidos da região visceral (abdômen) são delimitados. Nesta pesquisa optou-se por utilizar a delimitação escolhida por mais autores; segmentar a região visceral usando como base a parte mais externa dos músculos do abdômen. No entanto, mesmo que esta delimitação facilite na separação dos tecidos adiposos, ela impossibilita que os tecidos musculares e vísceras sejam quantificados, uma vez que as vísceras e os músculos possuem a mesma intensidade de HU. Sendo assim, sugere-se a utilização da parte interna dos músculos para a identificação da região visceral, pois, dessa maneira, seria possível quantificar músculos e tecidos derivados, como gorduras inter e intra musculares no abdômen.

Constatou-se também que devido à fáscia (da coxa) ser uma membrana muito fina e de pouca visibilidade, um estudo mais aprofundado sobre técnicas que possibilitem seu realce deve

ser feito. Desse modo, utilizando a fáschia mais realçada em conjunto com a aplicação do método proposto neste trabalho, é provável que os resultados obtidos possam ser ainda melhorados, resultando em uma quantificação mais precisa dos tecidos da coxa.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADDISON, O.; MARCUS, R.; LASTAYO, P.; RYAN, A. Intermuscular fat: a review of the consequences and causes. *International Journal of Endocrinology*, v. 2014, n. 309570, p. 1–11, 2014.
- ALBUQUERQUE, M. A.; SILVA, E. L.; BARROS, K. N. N. O.; JUNIOR, S. F. A. X. Comparação entre coeficientes similaridade um aplicação em ciências florestais. *Matemática e Estatística em Foco*, v. 4, n. 2, p. 102–114, 2016.
- BANDEKAR, A. N.; NAGHAVI, M.; KAKADIARIS, I. A. Performance evaluation of abdominal fat burden quantification in ct. In: *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the*. Shanghai, China: IEEE, 2006. p. 3280–3283.
- BISHOP, C. M. *Pattern recognition and machine learning*. Cambridge, UK: Springer, 2006.
- BREIMAN, L. Random forests. *Machine learning*, v. 45, n. 1, p. 5–32, 2001.
- BUSHBERG, J. T. *The essential physics of medical imaging*. Philadelphia, USA: Lippincott Williams & Wilkins, 2002.
- CARLOS, M. T. Tomografia computadorizada: Formação da imagem e radioproteção. *LNMRI, IRD/CNEN*, 2002.
- CHAN, J. M.; RIMM, E. B.; COLDITZ, G. A.; STAMPFER, M. J.; WILLETT, W. C. Obesity, fat distribution, and weight gain as risk factors for clinical diabetes in men. *Diabetes Care*, v. 17, n. 9, p. 961–969, 1994.
- CHEEMA, B.; ABAS, H.; SMITH, B.; O’SULLIVAN, A.; CHAN, M.; PATWARDHAN, A.; KELLY, J.; GILLIN, A.; PANG, G.; LLOYD, B. et al. Investigation of skeletal muscle quantity and quality in end-stage renal disease. *Nephrology*, v. 15, n. 4, p. 454–463, 2010.
- 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.
- CORMACK, A. M. Early two-dimensional reconstruction (CT scanning) and recent topics stemming from it. *Journal of Computer Assisted Tomography*, v. 4, n. 5, p. 658–664, 1980.
- CRUM, W.; CAMARA, O.; HILL, D. Generalized overlap measures for evaluation and validation in medical image analysis. v. 25, p. 1451–61, 12 2006.

- DOUGHERTY, E. R.; LOTUFO, R. A. *Hands-on morphological image processing*. Bellingham, Washington USA: SPIE Publications, 2003.
- DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern classification*. New Jearsey, USA: John Wiley & Sons, 2012.
- DURHEIM, M. T.; SLENTZ, C. A.; BATEMAN, L. A.; MABE S. K .AND KRAUS, W. E. Relationships between exercise-induced reductions in thigh intermuscular adipose tissue, changes in lipoprotein particle size, and visceral adiposity. *American Journal of Physiology-Endocrinology and Metabolism*, v. 295, n. 2, p. E407–E412, 2008.
- FAWCETT, T. An introduction to ROC analysis. *Pattern Recognition Letters*, v. 27, n. 8, p. 861–874, 2006.
- FELIX, J. E. R. Tomografia computadorizada (TC) abordagem, dados técnicos e posicionamento do usuário. *Universidade Tecnológica Federal do Parana*, 2012.
- FERRUCCI, L.; STUDENSKI, S. *Diabetes, muscles, and the myth of Ulysses' bow*. 2009.
- FIELD, A. *Descobrimo a estatística usando o SPSS-2*. Porto Alegre, RS, Brasil: Bookman Editora, 2009.
- FISHBEIN, M. H.; MOGREN, C.; GLEASON, T.; STEVENS, W. R. Relationship of hepatic steatosis to adipose tissue distribution in pediatric nonalcoholic fatty liver disease. *Journal of Pediatric Gastroenterology and Nutrition*, v. 42, n. 1, p. 83–88, 2006.
- FREIRE, P. G. L.; FERRARI, R. J. Automatic iterative segmentation of multiple sclerosis lesions using Student's t mixture model and probabilistic anatomical atlases in FLAIR images. *Computers in Biology and Medicine*, v. 73, n. Supplement C, p. 10–23, 2016.
- GAMI, A. S.; WITT, B. J.; HOWARD, D. E.; ERWIN, P. J.; GAMI, L. A.; SOMERS, V. K.; MONTORI, V. M. Metabolic syndrome and risk of incident cardiovascular events and death: a systematic review and meta-analysis of longitudinal studies. *Journal of the American College of Cardiology*, v. 49, n. 4, p. 403–414, 2007.
- GARROUSTE-ORGEAS, M.; TROCHÉ, G.; AZOULAY, E.; CAUBEL, A.; LASSENCE, A. de; CHEVAL, C.; MONTESINO, L.; THUONG, M.; VINCENT, F.; COHEN, Y. et al. Body mass index. *Intensive Care Medicine*, v. 30, n. 3, p. 437–443, 2004.
- GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing (3rd Edition)*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 2006.
- GOODPASTER, B.; CHOMENTOWSKI, P.; WARD, B.; ROSSI, A.; GLYNN, N.; DELMONICO, M.; KRITCHEVSKY, S.; PAHOR, M.; NEWMAN, A. Effects of physical activity on strength and skeletal muscle fat infiltration in older adults: a randomized controlled trial. *Journal of Applied Physiology*, v. 105, n. 5, p. 1498–1503, 2008.
- GOODPASTER, B.; KRISHNASWAMI, S.; RESNICK, H.; KELLEY, D.; HAGGERTY, C.; HARRIS, T.; SCHWARTZ, A.; KRITCHEVSKY, S.; NEWMAN, A. Association between regional adipose tissue distribution and both type 2 diabetes and impaired glucose tolerance in elderly men and women. *Diabetes Care*, v. 26, n. 2, p. 372–379, 2003.

GOODPASTER, B.; THAETE, F.; KELLEY, D. Thigh adipose tissue distribution is associated with insulin resistance in obesity and in type 2 diabetes mellitus. *The American Journal of Clinical Nutrition*, v. 71, n. 4, p. 885–892, 2000.

GOODPASTER, B.; THAETE, F.; SIMONEAU, J.; KELLEY, D. Subcutaneous abdominal fat and thigh muscle composition predict insulin sensitivity independently of visceral fat. *Diabetes*, v. 46, n. 10, p. 1579–1585, 1997.

GOODPASTER, B. H. B.; PARK, S.; HARRIS, T.; KRITCHEVSKY, S.; NEVITT, M.; SCHWARTZ, A.; SIMONSICK, E.; TYLAVSKY, F.; VISSER, M.; NEWMAN, A. The loss of skeletal muscle strength, mass, and quality in older adults: the health, aging and body composition study. *The Journals of Gerontology Series A: Biological Sciences and Medical Sciences*, v. 61, n. 10, p. 1059–1064, 2006.

GOODPASTER B.H. CARLSON, C.; VISSER, M.; KELLEY, D.; SCHERZINGER, A.; HARRIS, T.; STAMM, E.; NEWMAN, A. Attenuation of skeletal muscle and strength in the elderly: The health abc study. *Journal of Applied Physiology*, v. 90, n. 6, p. 2157–2165, 2001.

GRAHAM, R. L.; YAO, F. F. Finding the convex hull of a simple polygon. *Journal of Algorithms*, v. 4, n. 4, p. 324–331, 1983.

HAAGA, J. R.; BOLL, D. *Computed Tomography & Magnetic Resonance Imaging Of The Whole Body E-Book*. Amsterdã: Elsevier Health Sciences, 2008.

HENDEE, W. R.; RITENOUR, E. R.; HOFFMANN, K. R. *Medical imaging physics*. New York: Wiley Online Library, 1992.

HOFFMANN, R. et al. *Análise de regressão: uma introdução à econometria*. Universidade de São Paulo, São Paulo, Brasil: Biblioteca Digital da Produção Intelectual - BDPI, 2016.

HOUNSFIELD, G. N. Computed medical imaging. *Medical physics*, v. 7, n. 4, p. 283–290, 1980.

IDA, M.; HIRATA, M.; HOSODA, K.; NAKAO, K. Abdomen specific bioelectrical impedance analysis (BIA) methods for evaluation of abdominal fat distribution. *Nihon rinsho. Japanese Journal of Clinical Medicine*, v. 71, n. 2, p. 262–265, 2013.

JACKSON, A.; POLLOCK, M. L.; GRAVES, J. E.; MAHAR, M. Reliability and validity of bioelectrical impedance in determining body composition. *Journal of Applied Physiology*, v. 64, n. 2, p. 529–534, 1988.

KAMEL, E. G.; MCNEILL, G.; HAN, T.; SMITH, F. W.; AVENELL, A.; DAVIDSON, L.; TOTHILL, P. Measurement of abdominal fat by magnetic resonance imaging, dual-energy x-ray absorptiometry and anthropometry in non-obese men and women. *International Journal of Obesity & Related Metabolic Disorders*, v. 23, n. 7, 1999.

KARAMPINOS, D.; BAUM, T.; NARDO, L.; ALIZAI, H.; YU, H.; CARBALLIDO-GAMIO, J.; YAP, S.; SHIMAKAWA, A.; LINK, T.; MAJUMDAR, S. Characterization of the regional distribution of skeletal muscle adipose tissue in type 2 diabetes using chemical shift-based water/fat separation. *Journal of Magnetic Resonance Imaging*, v. 35, n. 4, p. 899–907, 2012.

- KIM, Y.; PARK, J.; KIM, J.; PARK, C.; GONZALEZ, J.; LEE, S.; KIM, K.; OH, J. Computerized automated quantification of subcutaneous and visceral adipose tissue from computed tomography scans: Development and validation study. *JMIR Medical Informatics*, v. 4, n. 1, 2016.
- KLETTE, R.; ROSENFELD, A. *Digital geometry: Geometric methods for digital picture analysis*. Burlington, Massachusetts: Morgan Kaufmann, 2004.
- KULLBERG, J.; HEDSTRÖM, A.; BRANDBERG, J.; STRAND, R.; JOHANSSON, L.; BERGSTRÖM, G.; AHLSTRÖM, H. Automated analysis of liver fat, muscle and adipose tissue distribution from CT suitable for large-scale studies. *Scientific Reports*, v. 7, n. 1, p. 1–11, 2017.
- LAWS, K. *Texture Image Segmentation*. Tese (PhD dissertation) — University of South California, 1980.
- LÜRIG, C.; KOBELT, L.; ERTL, T. Hierarchical solutions for the deformable surface problem in visualization. *Graphical Models*, v. 62, n. 1, p. 2–18, 2000.
- MACHADO, P. Fundamentos de geometria plana. *COLEÇÃO EAD–MATEMÁTICA, EDITORA CAED-UFMG*, 2012.
- MANINI, T. M.; CLARK, B. C.; NALLS, M. A.; GOODPASTER, B. H.; PLOUTZ-SNYDER, L. L.; HARRIS, T. B. Reduced physical activity increases intermuscular adipose tissue in healthy young adults. *The American Journal of Clinical Nutrition*, v. 85, n. 2, p. 377–384, 2007.
- MANJUNATH, B. S.; MA, W. Texture features for browsing and retrieval of image data. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 18, n. 8, p. 837–842, 1996.
- NEMOTO, M.; YEERNUER, T.; MASUTANI, Y.; NOMURA, Y.; HANAOKA, S.; MIKI, S.; YOSHIKAWA, T.; HAYASHI, N.; OHTOMO, K. Development of automatic visceral fat volume calculation software for CT volume data. *Journal of Obesity*, v. 2014, 2014.
- NEWTON, H. B. *Handbook of neuro-oncology neuroimaging*. Cambridge, Massachusetts: Academic Press, 2016.
- NGUYEN, T. M.; WU, Q. M. J. Robust student's-t mixture model with spatial constraints and its application in medical image segmentation. *IEEE Transactions on Medical Imaging*, v. 31, n. 1, p. 103–116, 2012.
- OHSHIMA, S.; YAMAMOTO, S.; YAMAJI, T.; SUZUKI, M.; MUTOH, M.; IWASAKI, M.; SASAZUKI, S.; KOTERA, K.; TSUGANE, S.; MURAMATSU, Y. et al. Development of an automated 3D segmentation program for volume quantification of body fat distribution using CT. *Japanese Journal of Radiological Technology*, v. 64, n. 9, p. 1177–1181, 2008.
- ORGANIZATION., W. H. et al. Definition, diagnosis and classification of diabetes mellitus and its complications: report of a who consultation. part 1, diagnosis and classification of diabetes mellitus. 1999.
- PEDNEKAR, A.; BANDEKAR, A. N.; KAKADIARIS, I. A.; NAGHAVI, M. Automatic segmentation of abdominal fat from CT data. In: *Application of Computer Vision, 2005. WACV/MOTIONS'05 Volume 1. Seventh IEEE Workshops on*. Breckenridge, CO, USA: IEEE, 2005. v. 1, p. 308–315.

POSITANO, V.; CHRISTIANSEN, T.; SANTARELLI, M. F.; RINGGAARD, S.; LANDINI, L.; GASTALDELLI, A. Accurate segmentation of subcutaneous and intermuscular adipose tissue from mr images of the thigh. *Journal of Magnetic Resonance Imaging*, v. 29, n. 3, p. 677–684, 2009.

POWERS, D. M. Evaluation: from precision, recall and f-measure to ROC, informedness, markedness and correlation. 2011.

RUAN, X. Y.; GALLAGHER, D.; HARRIS, T.; ALBU, J.; HEYMSFIELD, S.; KUZNIA, P.; HESHKA, S. Estimating whole body intermuscular adipose tissue from single cross-sectional magnetic resonance images. *Journal of Applied Physiology*, v. 102, n. 2, p. 748–754, 2007.

SAHA, P. K.; UDUPA, J. K. Relative fuzzy connectedness among multiple objects: theory, algorithms, and applications in image segmentation. *Computer Vision and Image Understanding*, v. 82, n. 1, p. 42–56, 2001.

SALVADEO, D. H. P. *Filtragem de ruído em imagens tomográficas com baixa taxa de contagem utilizando uma abordagem bayesiana contextual*. Tese (PhD dissertation) — Universidade Estadual de São Carlos, 2013.

SARTORI-CINTRA, A.; AIKAWA, P.; CINTRA, D. Obesity versus osteoarthritis: beyond the mechanical overload. *Einstein (São Paulo)*, v. 12, n. 3, p. 374–379, 2014.

SEERAM, E. *Computed Tomography-E-Book: Physical Principles, Clinical Applications, and Quality Control*. Amsterdã: Elsevier Health Sciences, 2015.

SHIMOMURA, I.; FUNAHASHI, T.; TAKAHASHI, M.; MAEDA, K.; KOTANI, K.; NAKAMURA, T.; YAMASHITA, S.; MIURA, M.; FUKUDA, Y.; TAKEMURA, K. et al. Enhanced expression of pai-1 in visceral fat: Possible contributor to vascular disease in obesity. *Nature Medicine*, v. 2, n. 7, p. 800–803, 1996.

SIEMENS HEALTHCARE GMBH. *Entendendo a radiação médica - Uma fonte de conhecimento para pacientes e técnicos de saúde*. São Paulo, Brasil, 2016. Disponível em: <<http://www.radiacao-medica.com.br/tipos-de-imagens-medicas/raios-x/tomografia-computadorizada-ct/>>.

ST-PIERRE, J.; LEMIEUX, I.; VOHL, M.; PERRON, P.; G. érald T.; DESPRÉS, J.; GAUDET, D. Contribution of abdominal obesity and hypertriglyceridemia to impaired fasting glucose and coronary artery disease. *The American Journal of Cardiology*, v. 90, n. 1, p. 15–18, 2002.

STEHNO-BITTEL, L. Intermuscular fat: a review of the consequences and causes. *Physical Therapy*, v. 88, n. 11, p. 1265–1278, 2008.

TAN, C.; LI, K.; YAN, Z.; YANG, D.; ZHANG, S.; YU, H.; ENGELKE, K.; MILLER, C.; METAXAS, D. A detection-driven and sparsity-constrained deformable model for fascia lata labeling and thigh inter-muscular adipose quantification. *Computer Vision and Image Understanding*, v. 151, p. 80–89, 2016.

TAN, C.; YAN, Z.; ZHANG, S. An automated and robust framework for quantification of muscle and fat in the thigh. In: *22nd International Conference on Pattern Recognition*. Stockholm, Sweden: IEEE, 2014. (ICPR'14), p. 24–28.

TITTERINGTON, D. M.; SMITH, A. F. M.; MAKOV, U. E. *Statistical analysis of finite mixture distributions*. New York: Wiley, 1985.

TOKUNAGA, K.; MATSUZAWA, Y.; ISHIKAWA, K.; TARUI, S. A novel technique for the determination of body fat by computed tomography. *International Journal of Obesity*, v. 7, n. 5, p. 437–445, 1983.

TUSTISON, N. J.; AVANTS, B. B.; COOK, P. A.; ZHENG, Y.; EGAN, A.; YUSHKEVICH, P. A.; GEE, J. C. N4itk: improved n3 bias correction. *IEEE Transactions on Medical Imaging*, v. 29, n. 6, p. 1310–1320, 2010.

VISSER, M.; GOODPASTER, B.; KRITCHEVSKY, S.; NEWMAN, A.; NEVITT, M.; RUBIN, S.; SIMONSICK, E.; HARRIS, T. et al. Muscle mass, muscle strength, and muscle fat infiltration as predictors of incident mobility limitations in well-functioning older persons. *The Journals of Gerontology Series A: Biological Sciences and Medical Sciences*, v. 60, n. 3, p. 324–333, 2005.

VISSER, M.; KRITCHEVSKY, S.; GOODPASTER, B.; NEWMAN, A.; NEVITT, M.; STAMM, E.; HARRIS, T. Leg muscle mass and composition in relation to lower extremity performance in men and women aged 70 to 79: the health, aging and body composition study. *Journal of the American Geriatrics Society*, v. 50, n. 5, p. 897–904, 2002.

WAJCHENBERG, B. L. Subcutaneous and visceral adipose tissue: their relation to the metabolic syndrome. *Endocrine Reviews*, v. 21, n. 6, p. 697–738, 2000.

WATTJES, M.; KLEY, R.; FISCHER, D. Neuromuscular imaging in inherited muscle diseases. *European Radiology*, v. 20, n. 10, p. 2447–2460, 2010.

YIM, J.; HESHKA, S.; ALBU, J.; HEYMSFIELD, S.; KUZNIA, P.; HARRIS, T.; GALLAGHER, D. Intermuscular adipose tissue rivals visceral adipose tissue in independent associations with cardiovascular risk. *International Journal of Obesity (2005)*, v. 31, n. 9, p. 1400, 2007.

YOSHIDA, Y.; MARCUS, R.; LASTAYO, P. Intramuscular adipose tissue and central activation in older adults. *Muscle & Nerve*, v. 46, n. 5, p. 813–816, 2012.

YOSHIZUMI, T.; TADASHI-NAKAMURA, R.; YAMANE, M.; WALIUL-ISLAM, A.; MENJU, M.; YAMASAKI, K.; ARAI, T.; KOTANI, K.; FUNAHASHI, T.; YAMASHITA, S.; MATSUZAWA, Y. Abdominal fat: Standardized technique for measurement at CT. *Radiology*, v. 211, p. 283–286, 1999.

ZHANG, S.; ZHAN, Y.; DEWAN, M.; HUANG, J.; METAXAS, D. N.; ZHOU, X. S. Towards robust and effective shape modeling: Sparse shape composition. *Medical Image Analysis*, v. 16, n. 1, p. 265–277, 2012.

ZHAO, B.; COLVILLE, J.; KALAIGIAN, J.; CURRAN, S.; JIANG, L.; KIJEWski, P.; SCHWARTZ, L. H. Automated quantification of body fat distribution on volumetric computed tomography. *Journal of Computer Assisted Tomography*, v. 30, n. 5, p. 777–783, 2006.

ZOU, K. H.; WARFIELD, S. K.; BHARATHA, A.; TEMPANY, C. M.; KAUS, M. R.; HAKER, S. J.; WELLS, W. M.; JOLESZ, F. A.; KIKINIS, R. Statistical validation of image segmentation quality based on a spatial overlap index 1: Scientific reports. *Academic Radiology*, v. 11, n. 2, p. 178–189, 2004.

ŽUNIC, R. K. J. Combinatorial image analysis. 2006.