



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA

ROGÉRIO ANASTÁCIO

SEGMENTAÇÃO E VOLUMETRIA AUTOMÁTICA DE
FÍGADO A PARTIR DE IMAGENS TOMOGRÁFICAS

Uberlândia

2015

ROGÉRIO ANASTÁCIO¹

SEGMENTAÇÃO E VOLUMETRIA AUTOMÁTICA DE FÍGADO A PARTIR DE
IMAGENS TOMOGRÁFICAS

Dissertação de mestrado submetida ao Programa de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Uberlândia, como requisito parcial à obtenção do título de Mestre em Ciências.

Área de concentração: Engenharia Biomédica
Orientador: Profa. Dr. Ana Claudia Patrocínio

Uberlândia

2015

¹ A Bolsa de Estudos, para esta pesquisa, foi concedida pela FAPEMIG, Brasil.

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

A534s
2015 Anastácio, Rogério, 1984-
 Segmentação e volumetria automática de fígado a partir de imagens
tomográficas / Rogério Anastácio. - 2015.
 152 f. : il.

 Orientadora: Ana Claudia Patrocínio.
 Dissertação (mestrado) - Universidade Federal de Uberlândia,
Programa de Pós-Graduação em Engenharia Biomédica.
 Inclui bibliografia.

 1. Engenharia biomédica - Teses. 2. Processamento de imagens -
Teses. 3. Fígado - Tomografia - Teses. I. Patrocínio, Ana Claudia. II.
Universidade Federal de Uberlândia. Programa de Pós-Graduação em
Engenharia Biomédica. III. Título.

CDU: 62:61

ROGÉRIO ANASTÁCIO

SEGMENTAÇÃO E VOLUMETRIA AUTOMÁTICA DE FÍGADO A PARTIR DE
IMAGENS TOMOGRÁFICAS

Dissertação de mestrado submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Uberlândia, como requisito parcial à obtenção do título de Mestre em Ciências.

Área de concentração: Engenharia Biomédica

Uberlândia, 24 de Março de 2015.

Banca Examinadora:

Ana Claudia Patrocínio, Dr. – FEELT / UFU (Orientador)

Milena Bueno Pereira Carneiro, Dr. – FEELT / UFU

Homero Schiabel, Dr. – EESC / USP

Prof.^a Ana Claudia Patrocínio, Dr.
Orientador

Prof. Adriano Alves Pereira, Dr.
Coordenador da Pós-Graduação

Dedico esse trabalho à minha esposa Karin,
e à minha pequena Lara.

AGRADECIMENTOS

Primeiramente a Deus, por me dar forças nos momentos de turbulência e me guiar quando necessário.

À minha orientadora, professora Ana Claudia Patrocinio, uma grande mentora, pelos conhecimentos, paciência, amizade e orientação.

À minha família, por estar sempre presente ao meu lado, me apoiando.

Por todo o (des)apoio de meus amigos, que convieram comigo este importante período e entenderam a minha ausência nos encontros semanais.

Aos meus colegas de laboratório Alessandro, Amanda, Andrei, Bárbara, Bruno, Daniel, Dhainner, Fábio, Franciel, Gustavo, Luiza, Mariana, Rafael, Ricardo, Tulio por todo o apoio, ideias e risadas durante esses dois anos que se passaram.

Aos alunos de iniciação científica Cecília, Giulia, Leticia Mamere, Letícia Salomão e Taissa que contribuíram com o árduo e entediante trabalho de circular fígado, fatia a fatia.

Ao Dr. Túlio e Dr. João Bonin que contribuíram durante a execução de todo o trabalho de aquisição das imagens à validação da segmentação manual.

E a todos que contribuíram de alguma forma para esse trabalho.

“A menos que modifiquemos a nossa maneira de pensar, não seremos capazes de resolver os problemas causados pela forma como nos acostumamos a ver o mundo”.

(Albert Einstein)

RESUMO

O câncer de fígado é de alta complexidade para ser diagnosticado e tratado, porém não é o de maior ocorrência no Brasil, e a detecção é a melhor forma de reduzir a mortalidade por câncer. O exame de Tomografia Computadorizada (TC) da região abdominal é frequentemente utilizado na análise e diagnóstico de lesões hepáticas. O sistema de auxílio ao diagnóstico pode ser utilizado como uma ferramenta pelos médicos radiologistas na detecção do câncer hepático. Uma das primeiras etapas da construção de um sistema de auxílio ao diagnóstico para fígado é segmentação do órgão. O contraste radiológico do fígado com os outros órgãos da região abdominal é baixo e, dependendo da fatia que é observada na TC, um grande desafio que deverá ser contornado na segmentação. O objetivo deste trabalho é realizar a segmentação automática do fígado e calcular seu volume, utilizando para a segmentação o algoritmo de crescimento de região. Antes de ser realizada a segmentação do fígado, as fatias de tomografia computadorizada da região abdominal foram pré-processadas para a redução de ruído e realce de contraste. A segmentação foi então realizada a partir das fatias pré-processadas usando algoritmo de crescimento de região e lançamento automático de semente. A área de lançamento de semente também foi automatizada em formatos diferentes, retangular, elíptica e circular, o que influenciou no desempenho da técnica de segmentação e consequentemente na taxa de acerto do volume hepático. Obteve-se um acerto médio de 66,08% para a segmentação com lançamento de semente em região retangular, 75,56% para região elíptica e 94,14% para região circular. Logo, a seleção automática da área de lançamento de semente em formato circular se mostrou uma técnica robusta e com um bom resultado na segmentação hepática, sendo então considerada uma contribuição para o algoritmo de crescimento de região utilizado neste projeto.

Palavras-Chave: Segmentação automática do fígado. Volumetria hepática. Crescimento de região.

ABSTRACT

Liver cancer is highly complex to be diagnosed and treated, but is not the most frequent in Brazil, and the detection is the best way to reduce cancer mortality. And the computed tomography of the abdomen is often used in the analysis and diagnosis of hepatic lesion. The computer aided diagnosis can be used as a tool for the radiologists in the detection of liver cancer. One of the first steps of building a computer aided diagnosis for liver is the segmentation of the organ. The radiological liver contrast to the other organs in the abdominal region is low, and generally being a problem, depending on which slice is observed, to be overcome in the segmentation. The main objective of this work is to perform the automatic segmentation of the liver and calculate its volume, using the region growing algorithm segmentation. Before being performed the liver segmentation, the computed tomography slices of the abdomen are pre-processed for noise reduction and contrast enhancement. The segmentation was then performed beginning from the pre-processed slices using region growing algorithm and automatic seed launch. The seed launch area was also automated in different formats, rectangular, elliptical and circular, that influenced the performance of the segmentation technique and consequently the success rate of the hepatic volume calculation with average hit rate of 66.008% for segmentation with seed launch on rectangular area, 75.56% for the elliptical area and 94.14% for the circular area. Therefore the automatic selection of seed launching area in circular format proved to be a robust technique and with a good result in liver segmentation, and so can be considered a contribution to region growing algorithm used in this project.

Keywords: Automatic liver segmentation. Liver volume. Region growing.

LISTA DE FIGURAS

Figura 2.1 – (a) Imagem binária do abdome. (b) Fígado segmentado pelo algoritmo de crescimento de região.	26
Figura 2.2 – Resultado da segmentação automática.	26
Figura 2.3 – (a) Diagrama do sistema. (b) Resultado da segmentação.	27
Figura 2.4 – Resultado da segmentação proposta em [15].	28
Figura 2.5 – Resultado da segmentação proposta em [16].	28
Figura 2.6 – Resultados apresentados para o trabalho [17], (a) Fígado Segmentado. (b) Reconstrução tridimensional do fígado.	29
Figura 2.7 – Resultado da segmentação do fígado e de alguns tumores presentes na mesma fatia.	30
Figura 2.8 – (a) Sobreposição da segmentação com a fatia original. (b) Reconstrução volumétrica do fígado.	31
Figura 2.9 – Resultado da segmentação da metodologia utilizada em [20] [21].	31
Figura 2.10 – (a) Segmentação do fígado sobreposta com a fatia de TC da região abdominal. (b) Segmentação de lesão sobreposta com fígado segmentado (região mais escura).	32
Figura 2.11 – Modelagem tridimensional do fígado segmentado.	33
Figura 2.12 – Fígado segmentado por esta metodologia.	33
Figura 2.13 – (a) Fatia Original. (b) Fatia pré-processada com filtro de alargamento de contraste.	34
Figura 2.14 – Segmentação do fígado.	35
Figura 2.15 – (a) Segmentação manual da fatia. (b) Segmentação automática da mesma fatia.	36
Figura 2.16 – Fatia original com as bordas da segmentação automática realçada.	37
Figura 2.17 – Fígado segmentado após reconstrução tridimensional.	38
Figura 2.18 – Fígado segmentado.	38
Figura 2.19 – (a) Fígado segmentado em uma fatia. (b) Reconstrução do volume do fígado segmentado.	40
Figura 2.20 – (a) Resultado da segmentação automática do fígado e dos rins. (b) Volume do fígado e rins segmentado reconstruído tridimensionalmente.	41
Figura 2.21 – Resultado da segmentação do fígado em fatias com alto contraste radiológico.	42
Figura 2.22 – Resultado da segmentação hepática.	43

Figura 2.23 – Fígado segmentado pela técnica de [35].	43
Figura 2.24 – Resultado da segmentação hepática quando utilizado [36].	44
Figura 2.25 – Resultado da segmentação da metodologia [37].	45
Figura 2.26 – Resultado da segmentação dos melhores resultados apresentados em [38].	46
Figura 3.1 – As primeiras quatro gerações de tomógrafos, (a) Primeira Geração, (b) Segunda Geração, (c) Terceira Geração, (d) Quarta Geração.	48
Figura 3.2 – (a) Imagem de um retângulo medindo 30 unidades de área de lado e 50 unidades de área de altura. (b) Resultado do senograma do retângulo.	50
Figura 3.3 – Exemplo da disposição dos feixes de raios-X, (a) feixe paralelo, (b) feixe em leque e (c) feixe em cone.	51
Figura 3.4 – Exemplo de imagem de tomografia computadorizada.	52
Figura 3.5 – (a) Face diafragmática do fígado. (b) Face visceral do fígado.	55
Figura 3.6 – Melhoramento de intensidade de nível de cinza quando aplicado contraste radiológico no fígado onde (a) representa a fase arterial, (b) representa a fase portal e (c) representa a fase de equilíbrio.	57
Figura 3.7 – Fatia de TC de fígado (a) sem contraste radiológico, (b) fase arterial, (c) fase portal e (d) fase de equilíbrio.	58
Figura 4.1 – Máscara do operador Laplaciano com centro negativo.	62
Figura 4.2 – (a) Operador de Sobel Horizontal, (b) Operador de Sobel Vertical.	62
Figura 4.3 – Gráfico do comportamento da transformação logarítmica.	63
Figura 4.4 – Gráfico do comportamento da transformação de potência.	64
Figura 4.5 – Forma geral da função de alargamento de contraste.	65
Figura 5.1 – (a) Representação da imagem com as sub-regiões. (b) <i>Quadtree</i> representando a imagem completa.	68
Figura 5.2 – Representação de funcionamento da técnica de watershed.	69
Figura 5.3 – Representação da movimentação de uma gota de água para o mínimo regional.	70
Figura 5.4 – Representação de uma barragem construída.	71
Figura 5.5 – Em (a) está a imagem original. (b) Segmentação por crescimento de região (Área escura) com ponto de semente em (2,2). (c) Segmentação por crescimento de região (Área escura) alterando o ponto de semente para (3,3) utilizando tolerância convencional ($ f(m,n) \leq T$). (d) Resultado da segmentação por crescimento de região (Área escura) utilizando a técnica de nível de tolerância aditiva.	74
Figura 6.1 – (a) Menus do software <i>ImageJ</i> com a ferramenta de <i>freehand selection</i> selecionada, (b) fatia de TC com a área selecionada utilizando o software <i>ImageJ</i> , (c) Valor da	

mensuração da área da fatia que estava selecionada anteriormente, o valor é medido em milímetros.....	78
Figura 6.2 – Diagrama com as combinações de técnicas utilizadas no pré-processamento das fatias.	80
Figura 6.3 – (a) Fatia de TC do abdômen sem qualquer processamento de intensidade de nível de cinza, (b) histograma da fatia sem processamento.	82
Figura 6.4 – (a) Fatia de TC do abdômen após a aplicação do Janelamento, (b) histograma da fatia com o Janelamento.	83
Figura 6.5 – Aplicação de vários tamanhos da máscara do filtro de média aritmética, em (a) É a fatia somente com o janelamento, o filtro de média aritmética foi aplicado alterando somente o tamanho da máscara: (b) tamanho de vizinhança [3X3], (c) tamanho de vizinhança [9X9] e (d) tamanho de vizinhança [27X27].....	85
Figura 6.6 - Aplicação de vários tamanhos da máscara do filtro de média geométrica, em (a) é observado à fatia de TC com o janelamento, (b) utilizado uma máscara de tamanho de vizinhança [3X3], (c) a máscara tem o tamanho aumentado para [9X9] e em (d) a máscara utilizada é de tamanho [27X27].	86
Figura 6.7 – Em (a) é observado à fatia da região abdominal sem a aplicação do filtro de mediana (somente com janelamento), em (b) foi aplicado o filtro de mediana com a máscara de tamanho de [3X3], em (c) o filtro de mediana possui máscara de tamanho [9X9] e por fim em (d) o filtro de mediana aplicado tem a máscara de tamanho [27X27].....	87
Figura 6.8 – (a) Fatia de TC da região abdominal com a aplicação de janelamento. A aplicação do filtro de Wiener é realizada com os seguintes tamanhos de máscara: (b) [3X3], (c) [9X9] e [27X27].....	88
Figura 6.9 – (a) Fatia TC janelada da região hepática; Resultado do calculo da transformação logarítmica utilizando c igual à: (b) $c=0,0001$, (c) $c=20$ e (d) $c=100$	89
Figura 6.10 – (a) Fatia de TC janelada. Resultado do calculo da transformação exponencial com: (b) $C=30$, (c) $C=60$ e (d) $C=120$	90
Figura 6.11 – (a) Fatia de TC janelada. É calculada a transformação de potência com: (b) $\gamma=0,1$, (c) $\gamma=0,5$ e (d) $\gamma=1,5$	91
Figura 6.12 – (a) Forma geral do Alargamento de Contraste [9], (b) Forma utilizada para realizar a transformação de contraste, com os valores definidos empiricamente.....	92
Figura 6.13 – (a) Fatia TC janelada, em (b) Fatia após processamento pela transformação de alargamento de contraste.	93
Figura 6.14 – (a) Fatia Janelada; (b) Fatia após o processamento pelo operador Laplaciano..	94

Figura 6.15 - (a) Fatia janelada, (b) Fatia após o processamento pelos Operadores de Sobel.	95
Figura 6.16 – (a) Fígado segmentado; (b) Sobreposição do fígado segmentado na fatia original.....	96
Figura 6.17 – Fatia limiarizada mostrando somente os ossos.	97
Figura 6.18 – (a) Representação da forma de varredura da matriz da imagem para <i>VbE</i> , e em (b) para <i>VbD</i>	98
Figura 6.19 – (a) Representação da forma de varredura da matriz da imagem para <i>HbS</i> , e em (b) <i>HbI</i>	98
Figura 6.20 – Representação da localização dos pontos (<i>VbE</i> , <i>VbD</i> , <i>HbS</i> , <i>HbI</i>) na matriz da fatia de TC.	99
Figura 6.21 – Representação da máscara da região.....	100
Figura 6.22 – Fatia original na primeira coluna, na segunda coluna recorte com a porção do fígado em forma retangular da mesma fatia.	100
Figura 6.23 – Duas fatias com partes diferentes do fígado com suas respectivas ALSRE selecionadas.	102
Figura 6.24– Imagem resultante após a multiplicação da <i>imDI1</i> pela fatia original.....	103
Figura 6.25 – Imagem resultante da multiplicação da <i>imDI2</i> com a imagem <i>imRI</i>	104
Figura 6.26 – Imagem da ALSRC.....	105
Figura 7.1 – Seleção manual da região do fígado em diferentes partes do exame (na cor vermelha).	110
Figura 7.2 – Resultado da segmentação utilizando o filtro de média aritmética com a transformação gama sobreposta com fatia do grupo com contraste radiológico (a) e (b) e sem contraste radiológico (c) e (d).....	113
Figura 7.3 – Em (a, c, e, g) são as fatias segmentadas manualmente, enquanto em (b, d, f, h) são as fatias segmentadas de forma automática, com o ponto de semente em destaque.....	116
Figura 7.4 – (a) Fatia de TC de fígado da região abdominal, (b) sobreposição de uma fatia com janelamento que teve o fígado segmentado com a fatia original de TC. O ponto de semente está em destaque.	121
Figura 7.5 – (a) Fatia de TC de fígado da região abdominal, (b) sobreposição de uma fatia com janelamento que teve o fígado segmentado com a fatia original de TC.....	121
Figura 7.6 – (a) Fatia janelada, (b) Filtro de Média Aritmética combinado com Transformação Logarítmica, (c) Filtro de Média Aritmética combinado com Transformação Exponencial, (d) Filtro de Média Aritmética combinado com Transformação Gama, (e) Filtro de Média Geométrica combinado com Transformação Logarítmica, (f) Filtro de Média Geométrica	

combinado com Transformação Exponencial, (g) Filtro de Média Geométrica combinado com Transformação Gama, (h) Filtro de Mediana combinado com Transformação Logarítmica.	123
Figura 7.7 – (a) Filtro de Mediana combinado com Transformação Exponencial, (b) Filtro de Mediana combinado com Transformação Gama, (c) Filtro de Wiener combinado com Transformação Logarítmica, (d) Filtro de Wiener combinado com Transformação Exponencial, (e) Filtro de Wiener combinado com Transformação Gama.	124
Figura 7.8 – (a) Fatia original. Sobreposição entre a fatia original e o resultado da segmentação utilizando as técnicas de pré-processamento: (b) filtro de média aritmética combinada com a transformação logarítmica, (c) filtro de média aritmética combinada com a transformação exponencial, (d) filtro de média aritmética combinada com a transformação gama. O ponto de semente está em destaque.	127
Figura 7.9 – (a) Fatia original. Sobreposição entre a fatia original e o resultado da segmentação utilizando as técnicas de pré-processamento: (b) filtro de média geométrica combinada com a transformação logarítmica, (c) filtro de média geométrica combinada com a transformação exponencial, (d) filtro de média geométrica combinada com a transformação gama. O ponto de semente está em destaque.	130
Figura 7.10 – (a) Fatia original. Sobreposição entre a fatia original e o resultado da segmentação utilizando as técnicas de pré-processamento: (b) filtro de mediana combinada com a transformação logarítmica, (c) filtro de mediana combinada com a transformação exponencial, (d) filtro de mediana combinada com a transformação gama. O ponto de semente está em destaque.	133
Figura 7.11 – (a) Fatia original. Sobreposição entre a fatia original. (b) Fatia de TC sobreposta com a segmentação do fígado quando utilizado filtro de Wiener associado com a transformação logarítmica para realizar o pré-processamento. (c) Utilização do filtro de Wiener associado com a transformação exponencial, (d) filtro de mediana combinada com a transformação gama. O ponto de semente está em destaque.	136
Figura 7.12 – (a) Fatia de TC da região abdominal. Sobreposição da segmentação do fígado com a fatia de TC da região abdominal sendo pré-processada com: (b) Transformação de alargamento de contraste, (c) operador Laplaciano e (d) Operador Sobel. O ponto de semente está em destaque.	138
Figura 7.13 – Sequência de imagens segmentadas pela técnica de crescimento de região quando utilizado a ALSRC sobreposta com as fatias originais.	144
Figura 7.14 – Sequência de imagens segmentadas pela técnica de crescimento de região quando utilizado a ALSRCw sobreposta com as fatias originais.	145

LISTA DE QUADROS

Quadro 5.1 – Propriedades da segmentação.....	67
Quadro 6.1 – Algoritmo de segmentação manual.	77
Quadro 6.2 – Algoritmo do Alargamento de Contraste.....	92
Quadro 6.3 – Algoritmo usado para a aplicação do operador Laplaciano.	93
Quadro 6.4 – Algoritmo do Processamento pelos Operadores de Sobel.....	94
Quadro 6.5 – Algoritmo do cálculo da volumetria hepática.....	106

LISTA DE TABELAS

Tabela 3.1 – Exemplo de algumas <i>tags</i> do cabeçalho DICOM.....	53
Tabela 7.1 – Volumes calculados manualmente e pelo algoritmo de crescimento de região com suas respectivas taxas de acerto para cada uma das técnicas (Janelamento, transformação de alargamento de contraste, operador Laplaciano, filtro de média aritmética com transformação gama, operador de Sobel).	111
Tabela 7.2 – Erro Quadrático Médio do VP.....	112
Tabela 7.3 – Volume calculado de forma automática com ALSRR e de forma manual.....	114
Tabela 7.4 – Erro quadrático médio por exame observado a partir da comparação entre as fatias segmentadas de forma manual e automática.....	114
Tabela 7.5 – Resultados do Volume Manual e Automático (utilizando ALSRE e ALSRR) com as respectivas taxa de acerto e EQM.	118
Tabela 7.6 – Dados de pré-processamento da fatia somente com o janelamento com taxa de acerto e EQM.....	120
Tabela 7.7 – Dados pré-processamento da combinação do filtro de média aritmética com: transformação logarítmica, transformação exponencial e transformação gama. Dados medidos em centímetros cúbicos.	125
Tabela 7.8 – Dados de pré-processamento da combinação do filtro de média geométrica com: transformação logarítmica, transformação exponencial e transformação gama. Os dados medidos em centímetros cúbicos.....	128
Tabela 7.9 – Dados de pré-processamento da combinação do filtro de mediana com: transformação logarítmica, transformação exponencial e transformação gama. Os dados medidos em centímetros cúbicos.....	131
Tabela 7.10 – Dados de pré-processamento da combinação do filtro de Wiener com: transformação logarítmica, transformação exponencial e transformação gama. Os dados medidos em centímetros cúbicos. O ponto de semente está em destaque.....	134
Tabela 7.11 – Dados de pré-processamento da transformação de alargamento de contraste, do operador Laplaciano e do operador Sobel.	136
Tabela 7.12 – Resumo das técnicas de pré-processamento que tiveram melhores resultados, usando ALSRE.	139
Tabela 7.13 – Resultados das médias de VA comparado com a média de VM. Processadas com ALSRE.....	139

Tabela 7.14 – Volumes dos fígados calculados manualmente e automaticamente com as respectivas técnicas para o lançamento de sementes: ALSRR, ALSRE e ALSRC.	140
Tabela 7.15 – Resultados das médias de VA comparado com a média de VM e pré-processadas com media mais gama.	141
Tabela 7.16 – Resultados das médias de VA utilizando ALSRC, ALSRE e ALSRR em fatias pré-processadas com filtro de média aritmética com transformação gama e também o resultados das médias de VA utilizando ALSRC, ALSRE em fatias pré-processadas com filtro de Wiener com transformação gama.	142
Tabela 7.17 – EQM para as técnicas de lançamento de semente automático ALSRR, ALSRE, ALSRC em fatias pré-processadas com filtro de média aritmética com transformação gama e filtro de Wiener com transformação gama.	143

LISTA DE SIGLAS E ABREVIATURAS

2D	Bidimensional
3D	Tridimensional
ALSRC	Área de Lançamento de Semente em Região Circular
ALSRCw	Área de Lançamento de Semente em Região Circular pré-processado com filtro de Wiener
ALSRE	Área de Lançamento de Semente em Região Elíptica
ALSRR	Área de Lançamento de Semente em Região Retangular
ACPC	<i>Average Contrast and Peripheral Contrast</i>
CAD	<i>Computer Aided Diagnosis</i>
DM	Desvio Médio
DICOM	<i>Digital Imaging and Communications in Medicine</i>
EQM	Erro Quadrático Médio
HC	Hospital de Clínicas da Universidade Federal de Uberlândia
HU	<i>Hounsfield Unit</i>
HbS	Horizontal, da borda superior para o centro
HbI	Horizontal, da borda inferior para o centro
mA	Miliampères
MHU	<i>Million Heat Unit</i>
NEMA	<i>National Electrical Manufacturers Association</i>
PACS	<i>Picture Archiving and Communications Systems</i>
PET-CT	<i>Positron Emission Tomography</i>
kV	Quilovolts
kW	Quilowatts
SIFT	<i>Scale-invariant Feature Transform</i>
TC	Tomografia Computadorizada
VbD	Vertical, da borda direita para o centro
VbE	Vertical, da borda esquerda para o centro
VA	Volume Automático
VR	Volume Automático da Área de Lançamento de Semente em Região Retangular
VM	Volume Manual
VP	Volume Preliminar
WC	<i>Window Center</i>
WW	<i>Window Width</i>

SUMÁRIO

CAPÍTULO 1 INTRODUÇÃO GERAL 22

1.1	OBJETIVOS	23
1.2	OBJETIVOS ESPECÍFICOS.....	23
1.3	JUSTIFICATIVA	24
1.4	ESTRUTURA DA DISSERTAÇÃO	24

CAPÍTULO 2 ESTADO DA ARTE 25

2.1	SEGMENTAÇÃO COM ALGORITMO DE CRESCIMENTO DE REGIÃO	25
2.2	SEGMENTAÇÃO COM ALGORITMO DE CONTO RNO ATIVO	34
2.3	SEGMENTAÇÃO COM ALGORITMO ATLAS PROBABILÍSTICO	39
2.4	SEGMENTAÇÃO BASEADA EM OUTRAS TÉCNICAS	42

CAPÍTULO 3 TOMOGRAFIA COMPUTADORIZADA DE FÍGADO 47

3.1	A TOMOGRAFIA COMPUTADORIZADA	47
3.2	A GERAÇÃO DA IMAGEM TOMOGRÁFICA	49
3.2.1	<i>Transformada de Radon</i>	49
3.2.2	<i>Formação da fatia de Tomografia Computadorizada</i>	50
3.3	O PADRÃO DICOM	52
3.4	O FÍGADO E SUA IMAGEM TOMOGRÁFICA	54
3.4.1	<i>Fígado</i>	54
3.4.2	<i>Imagem tomográfica de fígado</i>	56

CAPÍTULO 4 TÉCNICAS DE PRÉ-PROCESSAMENTO 59

4.1	FILTROS DE SUAVIZAÇÃO E AGUÇAMENTO	59
4.1.1	<i>Filtro de Média Aritmética</i>	59
4.1.2	<i>Filtro de Média Geométrica</i>	60
4.1.3	<i>Filtro de Mediana</i>	60
4.1.4	<i>Filtro de Wiener</i>	60
4.1.5	<i>Operador Laplaciano</i>	61
4.1.6	<i>Operadores de Sobel</i>	62
4.2	TRANSFORMAÇÃO DE INTENSIDADE	63

4.2.1	<i>Transformação Logarítmica</i>	63
4.2.2	<i>Transformação Exponencial</i>	63
4.2.3	<i>Transformação de Potência (Gama)</i>	64
4.2.4	<i>Transformação Alargamento de Contraste</i>	65

CAPÍTULO 5 TÉCNICAS DE SEGMENTAÇÃO BASEADA EM REGIÃO..... 66

5.1	TÉCNICA DE SEGMENTAÇÃO BASEADA EM DIVISÃO E FUSÃO DE REGIÃO	67
5.2	TÉCNICA DE SEGMENTAÇÃO BASEADA EM TOPOGRAFIA E HIDROGRAFIA	69
5.3	TÉCNICA DE SEGMENTAÇÃO BASEADA EM CRESCIMENTO DE REGIÃO	72

CAPÍTULO 6 METODOLOGIA..... 75

6.1	EQUIPAMENTO UTILIZADO	75
6.2	AQUISIÇÃO DAS IMAGENS	75
6.3	SEGMENTAÇÃO MANUAL DO FÍGADO	76
6.4	PRÉ-PROCESSAMENTO	79
6.4.1	<i>Janelamento</i>	81
6.4.2	<i>Filtro de Média Aritmética</i>	84
6.4.3	<i>Filtro de Média Geométrica</i>	85
6.4.4	<i>Filtro de Mediana</i>	86
6.4.5	<i>Filtro de Wiener</i>	87
6.4.6	<i>Transformação Logarítmica</i>	88
6.4.7	<i>Transformação Exponencial</i>	89
6.4.8	<i>Transformação de Potência</i>	90
6.4.9	<i>Transformação Alargamento de Contraste</i>	91
6.4.10	<i>Operador Laplaciano</i>	93
6.4.11	<i>Operadores de Sobel</i>	94
6.4.12	<i>Combinação dos Efeitos das Técnicas</i>	95
6.5	SEGMENTAÇÃO UTILIZANDO ALGORITMO DE CRESCIMENTO DE REGIÃO	95
6.6	LANÇAMENTO DA SEMENTE	96
6.6.1	<i>Região Interna das Costelas</i>	96
6.6.2	<i>Área de lançamento de semente em região retangular</i>	99
6.6.3	<i>Área de lançamento de semente em região elíptica</i>	101
6.6.4	<i>Área de lançamento de semente em região circular</i>	103
6.7	VOLUMETRIA HEPÁTICA	105
6.7	DESCARTE DOS VOLUMES EXCEDIDOS	106
6.8	COMPARAÇÃO ENTRE SEGMENTAÇÃO AUTOMÁTICA E SEGMENTAÇÃO MANUAL.....	107
6.8.1	<i>Comparação de volume manual e automático</i>	107
6.8.2	<i>Comparação do Erro Estatístico</i>	107

CAPÍTULO 7 RESULTADOS E DISCUSSÃO 109

7.1	SEGMENTAÇÃO MANUAL DO FÍGADO	109
7.2	TESTES PRELIMINARES DE TÉCNICAS DE PRÉ-PROCESSAMENTO.....	110
7.3	AUTOMATIZAÇÃO DO ALGORITMO DE CRESCIMENTO DE REGIÃO (REGIÃO RETANGULAR)	113
7.4	MELHORIA DA AUTOMATIZAÇÃO DO ALGORITMO DE CRESCIMENTO DE REGIÃO (REGIÃO ELÍPTICA)	117
7.5	TÉCNICAS DE PRÉ-PROCESSAMENTO.....	119
7.5.1	<i>Janelamento.....</i>	<i>119</i>
7.5.2	<i>Combinações de filtros e transformações de intensidades</i>	<i>122</i>
7.6	RESULTADOS UTILIZANDO AS DIFERENTES TÉCNICAS DE LANÇAMENTO DE SEMENTE	140
7.7	CONSIDERAÇÕES FINAIS.....	146

CAPÍTULO 8 CONCLUSÕES..... 147

REFERÊNCIAS 149

Capítulo 1 INTRODUÇÃO GERAL

A mudança do perfil demográfico no Brasil, denominado de “envelhecimento” da população, está associado à transformação nas relações das pessoas com seus ambientes, alterando, assim, o perfil de morbimortalidade. E assim tem reduzido à incidência de doenças infectocontagiosas, mudando o centro da atenção dos problemas ocasionados por doenças e mortes na população brasileira para as doenças crônico-degenerativas, provocando desta maneira alteração no repertório da vigilância epidemiológica [1].

A vigilância epidemiológica de câncer produz informações uteis para a tomada de decisões. O desenvolvimento da maioria dos cânceres, nome dado a mais de 100 tipos diferentes de doenças que possuem em comum o crescimento caótico de células com comportamento anômalo potencialmente invasivo, necessita de múltiplas etapas que ocorrem ao longo de muitos anos. Desta maneira, eliminando a exposição aos fatores determinantes, alguns tipos de câncer podem ser evitados [1].

O câncer de fígado é de alta complexidade para ser diagnosticado e tratado, porém não é o de maior ocorrência no Brasil [2]. Em pacientes que tiveram detecção do câncer em estágios avançados, a taxa de sobrevivência em cinco anos foi de apenas 15%. Em contrapartida, quando este tipo de câncer é detectado nos estágios iniciais, esta taxa de sobrevivência sobe para 60-70%, considerando mesmo período [3]. Então, se for detectado o potencial de malignidade antes das células tornarem-se malignas, ou na fase inicial da doença, é observado uma condição favorável ao tratamento [1].

A melhor forma para reduzir a mortalidade por câncer é através da detecção precoce, ou seja, a prevenção. E o exame de Tomografia Computadorizada (TC) da região abdominal é frequentemente utilizado para análise e diagnóstico de lesões hepáticas. Porém uma metodologia que seja mais confiável e precisa é necessária para auxiliar o médico radiologista na diferenciação de lesões hepáticas malignas e benignas [4].

Uma das tecnologias que costuma ser utilizada para auxiliar os médicos radiologistas na análise e diagnóstico de lesões hepáticas é o sistema de auxílio ao diagnóstico, do inglês *Computer Aided Diagnosis – CAD*. E uma das primeiras etapas da construção de um sistema CAD é a segmentação do órgão de interesse (fígado) [5, 6].

O fígado é o maior órgão em volume na cavidade abdominal, porém, existem diversos órgãos adjacentes (coração, rins e baço) e é baixo o contraste radiográfico entre eles, o que se torna um problema na segmentação, dependendo de qual fatia está sendo observada na TC [7, 8].

Desta forma, para melhorar o contraste dos níveis de cinza na segmentação é necessário a utilização de técnicas de pré-processamento, para que os ruídos presentes nas fatias de TC sejam reduzidos (sem degradar a imagem) e também, para que as bordas dos órgãos internos do abdome, em especial do fígado, sejam aguçadas [8, 9].

Após a segmentação do fígado, na maioria das vezes, é realizado o cálculo do volume hepático, devido à importância que a volumetria tem no planejamento de cirurgias hepáticas, como por exemplo, transplantes de fígado, em que é crucial o conhecimento do volume do fígado para efetivar o procedimento [10-12].

1.1 Objetivos

Assim, o objetivo deste trabalho é realizar a segmentação do fígado e calcular seu volume, utilizando para a segmentação o algoritmo de crescimento de região.

1.2 Objetivos Específicos

Os objetivos específicos deste trabalho são:

- Avaliar a influência das técnicas de pré-processamento no resultado da segmentação automática;
- Desenvolver metodologia de lançamento automático de semente, automatizando totalmente a segmentação;
- Calcular volume do fígado a partir das fatias segmentadas automaticamente;
- Comparar o volume da segmentação manual com o volume calculado a partir das imagens segmentadas automaticamente.

1.3 Justificativa

O desenvolvimento de ferramentas mais precisas e confiáveis para auxiliar os médicos radiologistas se faz necessário. Como a segmentação é o primeiro passo para a construção do sistema CAD, neste trabalho é proposto a segmentação hepática automática. Então, para a segmentação hepática mais especificamente, é sugerida a utilização da técnica de crescimento de região, por ser uma abordagem de baixo custo computacional e também uma técnica que está entre as mais utilizadas na segmentação hepática [2].

Para que a técnica de crescimento de região funcione adequadamente é imprescindível que o ponto de semente seja definido corretamente [3, 4, 5]. Então foi desenvolvida uma metodologia para que seja realizado o lançamento da semente de forma automática, baseada em vários parâmetros, como o cálculo de centroide e a análise do nível de cinza.

Além disso, medidas como o volume hepático devem ser calculadas a partir das fatias do fígado segmentadas, para que se tenham valores mais reais.

1.4 Estrutura da Dissertação

Além deste capítulo introdutório, que apresenta a motivação e os objetivos a serem alcançados, o texto será dividido estruturalmente da seguinte forma:

- **Capítulo** Erro! Fonte de referência não encontrada.: Apresentação de trabalhos correlacionados com o tema proposto.
- **Capítulo Capítulo 3:** Apresentação do fígado e sua imagem tomográfica.
- **Capítulo Capítulo 4:** Descrição das técnicas de pré-processamento utilizadas.
- **Capítulo Capítulo 5:** Descrição das técnicas de segmentação baseadas em regiões.
- **Capítulo Capítulo 6:** Descrição da metodologia de pré-processamento e segmentação automática utilizada.
- **Capítulo 7:** Resultados da utilização das técnicas de pré-processamento e segmentação nas fatias tomográficas de fígado.
- **Capítulo 8:** Apresentação das conclusões finais, bem como propostas para trabalhos futuros que podem ser realizados a partir dessa pesquisa.


Capítulo 2 ESTADO DA ARTE

Este capítulo é reservado para apresentar trabalhos de diferentes pesquisadores, citando a metodologia que foi adotada para realizar a segmentação do fígado, bem como seus resultados e contribuições.

2.1 Segmentação com algoritmo de Crescimento de região

A técnica de segmentação por crescimento de região vem sendo vastamente utilizada na literatura em aplicações para segmentação hepática. Em exames de TC de 31 pacientes, para realizar a segmentação do fígado, os pesquisadores Hsien-Wen C. e Tzu-Chao C. [10] aplicaram metodologia de segmentação automática, em que a partir da distribuição da escala de nível de cinza da fatia, é obtida a região de interesse do fígado e, com isso, é aplicada uma técnica de binarização, que contenha o fígado (Figura 2.1(a)). O resultado desta etapa é uma imagem binária com o fígado e alguns outros tecidos como baço. Então, o algoritmo de crescimento de região é aplicado nesta imagem para fazer a segmentação do fígado (Figura 2.1(b)) e, por fim, a segmentação final é escalada com resolução de voxel para medir o volume real. O resultado observado para o volume médio calculado pelo algoritmo de crescimento de região foi de $1356 \pm 218\text{cm}^3$ e o volume médio calculado manualmente de $1227 \pm 192\text{cm}^3$, o que representa 89,5% de acerto médio. Apesar de a metodologia ter segmentado de forma satisfatória o fígado, ela não conseguiu separar os lobos hepáticos direito e esquerdo.


Figura 2.1 – (a) Imagem binária do abdome. (b) Fígado segmentado pelo algoritmo de crescimento de região.



Fonte: [10].

No caso do trabalho de Gambino O. e colaboradores [13], foi empregado uma metodologia tridimensional da combinação de análise de atributos de textura (Matrix de co-ocorrência 2D, filtro de Gabor, Semi-variograma 2D e 3D) para a seleção automática do ponto de semente (Voxel) para a segmentação ser realizada pelo algoritmo de crescimento de região, onde foram utilizados exames de TC de 5 pacientes. O volume final do exame é obtido somando os volumes individuais das fatias. Os resultados obtidos com esta metodologia são apresentados na Figura 2.2, sendo observada boa segmentação nas fatias que possuíam volumes maiores, porém em fatias com volumes menores (início e fim da região hepática) não foram geradas estatísticas significantes.


Figura 2.2 – Resultado da segmentação automática.



Fonte: [13].

O trabalho desenvolvido por Wu J. e colaboradores [14], apesar de ser desenvolvido para a segmentação dos rins, o mesmo teve a sua inserção nesta coletânea de trabalhos por se tratar de um trabalho que foi utilizado como base para o que foi desenvolvido em [13]. Desta maneira os autores comparam o resultado da segmentação dos rins a partir de análise de textura com várias técnicas: Matrix de co-ocorrência 2D, filtro de Gabor e Semi-variograma 2D e 3D. E então, a partir do resultado da análise de textura, realizarem o lançamento de semente automático, porém, necessitando da seleção da região de interesse, para ser utilizado no algoritmo de crescimento de região. Este algoritmo foi testado em 12 séries de exames de ressonância magnética da região abdominal, como alvo da segmentação foi definido os rins, podendo verificar que a melhor seleção do ponto de semente, e consequente melhor segmentação, se deu quando utilizada a técnica de semi-variograma 3D (Figura 2.3(a)), porém a mais rápida foi a técnica de semi-variograma 2D (Figura 2.3(b)).

Figura 2.3 – (a) Diagrama do sistema. (b) Resultado da segmentação.




Fonte: [14].

No trabalho de Yanhui S., Kunyu T. e Jian W. [15] é avaliado o resultado da segmentação do algoritmo de crescimento de região para a segmentação de fígado, porém utilizando uma modificação que foi realizada no algoritmo de crescimento de região média de contraste e contraste periférico, do inglês *average contrast and peripheral contrast (ACPC) seed region growing*, para ser aplicável em objetos maiores, sendo feito três maiores incrementos no algoritmo, o primeiro relacionado à seleção do ponto de semente considerando a similaridade da região, o segundo incremento é com o lançamento de sementes múltiplas para objetos com grande variação de níveis de cinza para melhorar o resultado da segmentação e o terceiro incremento foi a realização, em cada iteração do

algoritmo de crescimento de região, da atualização de algumas bordas internas e externas para reduzir o custo computacional. Com a modificação do algoritmo foi obtido um bom resultado (Figura 2.4) quando comparado com o método ACPC convencional, comparando o tempo de processamento e a segmentação de objetos com grande variação de níveis de cinza.


Figura 2.4 – Resultado da segmentação proposta em [15].



Adaptado de [15].

O trabalho desenvolvido por Pohle R. e Toennies K. D. [16], testa em imagens provenientes de TC (região abdominal) e de ressonância magnética, um método automático com aprendizado do critério de homogeneidade para segmentação pelo algoritmo de crescimento de região, utilizando uma área de pixels com menor variação de gradiente como ponto de semente. O resultado do método proposto (Figura 2.5) é avaliado com o resultado da segmentação semiautomática utilizando avaliação por métodos de discrepância empírica. Foi observado uma melhor preservação da conectividade das regiões quando comparado com outros métodos (Watershed, divisão e fusão).


Figura 2.5 – Resultado da segmentação proposta em [16].



Fonte: [16].

No trabalho de Yufei C. e colaboradores [17] é utilizado o algoritmo de crescimento de região para realizar a segmentação do fígado em exames de TC, através da aplicação de filtro anisotrópico e função gaussiana para calcular a função de verossimilhança do fígado na etapa de pré-processamento das imagens. O ponto de semente é definido apenas na primeira fatia do exame e para definir os pontos de sementes das fatias seguintes é utilizado o cálculo do centroide para encontrar o centro de massa e guiar o ponto de semente, para que, então, seja realizada a segmentação do fígado (Figura 2.6(a)). Após a segmentação de todas as fatias é realizada a reconstrução tridimensional da segmentação (Figura 2.6(b)). Com esta metodologia é obtido um resultado eficiente com bom desempenho da segmentação hepática, segundo os autores.


Figura 2.6 – Resultados apresentados para o trabalho [17], (a) Fígado Segmentado. (b) Reconstrução tridimensional do fígado.



Fonte: [17].

Os pesquisadores Jayanthi M. e Kanmani B. [18], utilizando um conjunto de dados composto por 5 exames da região abdominal de TC, realizando o pré-processamento nas imagens com melhoramento de contraste e suavização morfológica, determinaram o ponto de semente para ser utilizado no algoritmo de crescimento de região a partir do cálculo do centroide na maior região conectada, após realizar o processo de erosão morfológica na fatia de TC. Com esse processo foi possível segmentar o fígado e também lesões hepáticas presentes na fatia, conforme mostra a Figura 2.7.

Figura 2.7 – Resultado da segmentação do fígado e de alguns tumores presentes na mesma fatia.




Fonte: [18].

Já no trabalho dos pesquisadores Kumar, S. S., Moni R. S. e Rajeesh J. [19] foi utilizada a técnica de crescimento de região para realizar a segmentação automática do fígado e lesões hepáticas em 10 exames de TC da região abdominal. No pré-processamento é aplicado o filtro de mediana para remover o ruído granular presente na fatia de TC, e analisando o histograma da imagem pré-processada, o maior pico (excluindo a intensidade de nível de cinza do fundo e dos ossos), representa a intensidade média da região do fígado. Uma estimativa grosseira da intensidade mínima e máxima dos pixels do fígado é calculada a partir do histograma, tornando assim possível encontrar a região interna do fígado automaticamente quando utilizado a função de verossimilhança neste histograma.

A imagem originada deste procedimento contém alguns outros órgãos, que são removidos com erosão morfológica, e a maior região erodida que está conectada é considerada a região para ser utilizada no algoritmo de crescimento de região, onde o ponto de semente é definido pelo cálculo do centroide desta região, obtendo assim o fígado segmentado (Figura 2.8(a)). Depois ocorre a reconstrução tridimensional do volume hepático (Figura 2.8(b)).

Por esta metodologia o erro médio encontrado foi de 1,52% na comparação do volume automático com o volume manual, a média da taxa de acerto foi de 97,5% e, por fim, considerando o volume médio do fígado, foi encontrado $1134,84 \text{ cm}^3$ para o volume automático que em comparação com o volume manual calculado, que foi de $1148,83 \text{ cm}^3$, representa um bom resultado para a segmentação do fígado.


Figura 2.8 – (a) Sobreposição da segmentação com a fatia original. (b) Reconstrução volumétrica do fígado.



Fonte: [19].

A pesquisa desenvolvida pelo Zhennan Y. e colaboradores [20] assim como o trabalho de Junbin H. e colaboradores [21], envolve segmentação tridimensional do fígado (com a técnica de Ray Casting) em exames de TC utilizando algoritmo de crescimento de região. O primeiro passo realizado foi o pré-processamento nas imagens com limiarização e também aguçamento de bordas baseada em análise estatística. Depois de pré-processar todas as fatias do exame foi realizado a reconstrução tridimensional do fígado, baseado no algoritmo de Ray Casting, para aplicar o algoritmo de crescimento de região, selecionando o ponto de semente manualmente. Os resultados do fígado segmentado tridimensionalmente são comparados com a segmentação que foi realizada com o algoritmo de crescimento de região bidimensional (Figura 2.9). Uma melhor segmentação do fígado foi obtida com a técnica de segmentação tridimensional.


Figura 2.9 – Resultado da segmentação da metodologia utilizada em [20] [21].



Fonte: [20].

Os pesquisadores Abd-Elaiz O. F., Sayed M. S. e Abdullah M. I. [22] utilizaram o algoritmo de crescimento de região automático para fazer a segmentação do fígado e de suas lesões em 15 exames de TC da região abdominal, onde, primeiramente, foi realizado o pré-processamento com um filtro de mediana e também é utilizada análise de histograma e processamento com erosão morfológica. O ponto de semente é definido automaticamente através do cálculo do centroide na imagem erodida. Os resultados da segmentação automática foram comparados com a segmentação calculada manualmente realizada por especialista e, com isso, obteve-se aproximadamente a média de 98% de taxa de acerto com taxa de erro médio de $1,2 \pm 0,7\%$ para a segmentação do fígado (Figura 2.10(a)) e aproximadamente a média de 99% de taxa de acerto para a segmentação de lesões (Figura 2.10(b)) com o erro médio de $0,2 \pm 0,2\%$. Os resultados foram considerados promissores pelos autores.

Figura 2.10 – (a) Segmentação do fígado sobreposta com a fatia de TC da região abdominal. (b) Segmentação de lesão sobreposta com fígado segmentado (região mais escura).




Fonte: [22].

No trabalho de Campadelli P., Casiraghi E. e Lombardi G. [23] é apresentada a segmentação automática do fígado em exames de TC utilizando a técnica de crescimento de região de duas formas. O pré-processamento realizado é modelagem tridimensional do abdome, sendo detectada a maior região 3D conectada, que corresponde ao fígado e parte do coração (removendo o coração do volume com algoritmo de crescimento de região). Depois, através de projeções de plano em três eixos, é detectado o ponto de semente para ser utilizado no algoritmo de crescimento de região tridimensional (Figura 2.11). A segunda técnica desenvolvida para a segmentação do fígado é derivada da primeira técnica, sendo que na segunda técnica é tomado um maior cuidado em relação aos órgãos com intensidades de níveis de cinza próximas às do fígado (utilizando *graph-cut*). O resultado obtido, utilizando

10 exames de TC, para a primeira técnica foi de 95% de taxa de acerto média e 92% de taxa de acerto média para a segunda técnica quando comparado com a segmentação manual.


Figura 2.11 – Modelagem tridimensional do fígado segmentado.



Fonte: [23].

A pesquisa de Wenhan W. e Xihe G. [24] foi desenvolvida com o intuito de apresentar a segmentação hepática em alta velocidade em exames de TC. Utilizando técnica de janelamento e análise do nível de intensidade média do fígado (verificação manual), associado com remoção dos ossos e algoritmo de crescimento de região (para remoção de regiões que não pertencem ao fígado), o resultado desta etapa é uma coleção de pontos discretos do fígado e para ser obtida a região hepática completa é realizado o processo de preenchimento dos pontos (Figura 2.12). E foi observado pelos resultados que esta metodologia é aproximadamente 59 vezes mais rápida que a técnica de contornos ativos (Snake) e 107 vezes mais rápido que as técnicas baseadas em limiarização, porém constataram a ocorrência de excesso de segmentação no fígado.


Figura 2.12 – Fígado segmentado por esta metodologia.



Fonte: [24].

O trabalho desenvolvido por Mostafa A. e colaboradores [25] avaliou o efeito de vários filtros de pré-processamento (transformação de alargamento de contraste (Figura 2.13(b)), transformação de alargamento de contraste inversa, filtro de convolução, filtro de mediana, filtro de média e transformação logarítmica) combinados com a segmentação do fígado utilizando a técnica de crescimento de região. Após a aplicação desta metodologia em 26 imagens (Figura 2.13(a)) os melhores resultados foram observados para a transformação de alargamento de contraste, taxa de acerto igual a 84,23% e Erro Quadrático Médio (EQM) igual a 0,19 cm³, e a combinação de alargamento de contraste e filtro de média, com taxa de acerto igual a 83,26% e EQM igual a 0,17.

Figura 2.13 – (a) Fatia Original. (b) Fatia pré-processada com filtro de alargamento de contraste.



Fonte: [25].

2.2 Segmentação com algoritmo de contorno ativo

Além do algoritmo de crescimento de região outras técnicas de segmentação também podem ser utilizadas como no caso do trabalho de Suzuki K. e colaboradores [26], que em seu estudo utilizou a técnica de contorno ativo tridimensional para segmentar o fígado de forma automática. Primeiramente a fatia de TC é pré-processada com um filtro de difusão anisotrópico para remoção de ruído, depois é utilizado um filtro de aguçamento de bordas (filtro de gradiente) para, então, aplicar a técnica de contorno ativo tridimensional geodésico para a segmentação do fígado. O volume do fígado segmentado total é obtido pela soma dos volumes de cada fatia. Os resultados da volumetria automática (Figura 2.14(a)) são

comparados com a segmentação do fígado obtida com um método interativo (utilização do software comercial *Volume Tracing in Advanced Vessel Analysis* da empresa *Philips Healthcare*) e também com a segmentação do fígado manual, obtendo a média de $1520 \pm 378 \text{ cm}^3$ para o volume automático, $1553 \pm 343 \text{ cm}^3$ (Figura 2.14(b)) para o volume do fígado calculado de forma interativa e $1486 \pm 343 \text{ cm}^3$ para o volume calculado manualmente, e assim a taxa de acerto para o volume automático e interativo foi de 95% e 97% respectivamente.

Figura 2.14 – Segmentação do fígado.




Fonte: [26].

No trabalho de Abdel-massieh N. H., Hadhoud M. M. e Moustafa K. A. [27] também foi utilizada a técnica automatizada de contorno ativo (snakes), que foi melhorada para obter a segmentação hepática melhor definida (segmentação mais fidedigna). Primeiramente foi realizado o pré-processamento nas fatias com técnica de limiarização Isodata para remoção da área externa a caixa torácica, e depois um filtro de média móvel para remover ruído preservando as bordas, em seguida é utilizado uma abordagem estatística tridimensional para diferenciar quais os voxels que pertencem ao parênquima hepático ou ao fundo da fatia, para que então seja aplicada a técnica de limiarização adaptativa.

Na sequência, a fatia é subdividida em 64 janelas e calculada a média e desvio padrão das intensidades de níveis de cinza para cada janela, para poder ser realizado uma análise de homogeneidade, agrupando as janelas semelhantes, então, a técnica de morfologia matemática é utilizada para separar o fígado (considerando o fígado como a maior região homogênea) dos outros órgãos, obtendo, desta maneira, uma segmentação mais grosseira do fígado. Para fazer o refinamento da segmentação é utilizada a técnica de contorno ativo (snakes). Os resultados da segmentação automática (Figura 2.15(b)), por esta metodologia em 15 exames de TC, foi

de 99% de taxa de acerto e com média de erro de 0,95%, fazendo comparação com a segmentação manual (Figura 2.15(a)), realizada por especialista.


Figura 2.15 – (a) Segmentação manual da fatia. (b) Segmentação automática da mesma fatia.



Fonte: [27].

Também no trabalho desenvolvido por Suzuki K. e colaboradores [28], foi utilizada técnica de contorno ativo geodésico, mas associado com aguçamento de bordas, para realizar a segmentação do fígado em exames de TC da fase portal. Na etapa de pré-processamento foi utilizado o filtro de difusão anisotrópica para remoção de ruído e filtro gaussiano para aguçamento de bordas para que, então, na etapa de segmentação, fosse aplicado o algoritmo de contorno ativo geodésico seguido de uma limiarização (deixando a segmentação binária) e também a aplicação do filtro de mediana para eliminar possíveis anomalias. Em seguida foi aplicada a função de rotulagem de componentes conexos na imagem binária, obtendo assim, a área de cada região do fígado extraída. O volume foi obtido somando estas áreas. Os resultados obtidos com esta técnica foram comparados com a segmentação manual (realizado por especialista), onde a média de volume do fígado automático foi de 1504 cm^3 (na Figura 2.16 é observado um exemplo desta segmentação) enquanto o volume médio da segmentação manual foi de 1457 cm^3 .

Figura 2.16 – Fatia original com as bordas da segmentação automática realçada.




Fonte: [28].

No trabalho Massoptier L. e Casciaro S. [29] foi utilizada a técnica de contorno ativo, porém, combinado com fluxo de vetor gradiente para realizar a segmentação do fígado de forma automática, e utilizando abordagem tridimensional para a segmentação.

A primeira etapa da técnica é realizar o pré-processamento utilizando filtro de média móvel tridimensional para remover ruído preservando as bordas, na sequência, o algoritmo procura pela fatia do fígado com volume mais significativo (maior volume) no exame, onde é realizada a divisão da fatia em 64 regiões quadradas, para ser calculado a média e o desvio padrão (ordenando os resultados). Sabendo que o fígado é homogêneo e considerando a intensidade de nível de cinza, além de ser o maior órgão do abdome. Assim é selecionada a média de intensidade que pertence a região do fígado, e com esta informação é utilizado a função de limiarização automática baseada em histograma na reconstrução tridimensional do exame para selecionar os voxels que pertencem ao tecido hepático. Com isso é obtido um volume grosseiro do fígado, e para refinar o volume hepático segmentado é aplicada a técnica de contorno ativo combinado com fluxo de vetor gradiente neste volume, obtendo, desta maneira, o fígado segmentado (Figura 2.17).

Quando aplicada a técnica de segmentação, em 21 exames de TC da região abdominal, foi obtido a média de taxa de acerto $94,4\% \pm 1,1\%$ quando comparado o volume automático do fígado com o volume manual calculado por especialista. Portanto, foi observada uma boa eficiência na segmentação com este método proposto.

Figura 2.17 – Fígado segmentado após reconstrução tridimensional.




Fonte: [29].

O trabalho de E-Liang C. e colaboradores [30] descreve como é realizada automaticamente a segmentação do fígado e a detecção de dois tipos de câncer hepático (Hemangioma e hepatoma), utilizando o conceito do modelo Browniano fracionário normalizado para encontrar as bordas do fígado. E em seguida é aplicado um modelo de contorno deformável (Contorno ativo) para contornar o fígado precisamente.

A forma de classificação de câncer é realizado através de rede neural probabilística modificada em conjunto com descritores que são gerados por atributos fractais e matriz de co-ocorrência.

Com a aplicação desta metodologia nos exames de TC de 30 pacientes, foi obtida uma boa segmentação hepática (Figura 2.18) e uma taxa de acerto de 83% na classificação de câncer hepático.

Figura 2.18 – Fígado segmentado.



Fonte: [30].

2.3 Segmentação com algoritmo Atlas probabilístico

Os pesquisadores Shengjun Z. e Yuanzhi C. [31] desenvolveram um *framework* tridimensional para segmentação automática do fígado em fatias que tiveram a aplicação de contraste radiológico em exames de TC, utilizando, para isso, modelo de intensidade e forma combinado com atlas probabilístico e mapa de probabilidade. Esta metodologia possui uma etapa de pré-processamento (utilizada na fase de treinamento e de teste), consistindo de alinhamento e rotação das fatias pelo centro de massa do pulmão para remover o deslocamento do corpo, e aplicação do filtro anisotrópico tridimensional para reduzir ruído e preservar o contorno do fígado. Todos os volumes são reamostrados para a mesma quantidade de fatias (100) utilizando de interpolação trilinear.

Na fase de treinamento são computadas as similaridades entre os conjuntos de dados (ordenando os de acordo com a similaridade). O atlas é composto do conjunto de dados da TC e do resultado de sua segmentação.

O mapa de probabilidade é constituído de cinco classes (fígado, coração, rins direito, osso e fundo), sendo gerado para cada classe um histograma por amostragem dos volumes da fase de treinamento. A função de verossimilhança é calculada para cada classe e, para encontrar o fígado é realizada a classificação do mapa de probabilidade da classe do fígado. Por fim é aplicado um refinamento verificando a continuidade, para a remoção de objetos que tenham sido adicionados a segmentação do fígado Figura 2.19(a).

Esta metodologia foi aplicada em 10 exames de TC, e os resultados mostram uma leve variação quando comparada a segmentação automática com a segmentação manual (Erro médio de $8,38 \pm 1,72\%$), demonstrando resultados promissores. Um exemplo de volume automático reconstruído tridimensionalmente é apresentado na Figura 2.19 (b).

Figura 2.19 – (a) Fígado segmentado em uma fatia. (b) Reconstrução do volume do fígado segmentado.




Fonte: [31].

No trabalho de Linguraru M. G. e colaboradores [32], foi utilizada a técnica de contorno ativo (geodésico) com técnica de atlas probabilístico para realizar a segmentação do fígado e dos rins. A construção do atlas probabilístico (com as informações de tamanho, volume, forma do fígado e rins) utiliza as informações da segmentação manual de exames de 10 pacientes sorteados aleatoriamente do banco de dados (257 Exames de TC de várias instituições). Para ser realizada a segmentação automática, em cada fatia, é aplicado o filtro de difusão anisotrópica para a redução de ruído e depois são utilizados dois modelos probabilísticos criados a partir das informações do atlas, para obter a estimativa inicial da posição dos órgãos, para que então seja aplicada a segmentação por contorno ativo geodésico.

A aplicação desta técnica, em 257 exames de TC da região abdominal, teve como resultado 96,2% do coeficiente DICE com 2,2% de erro. Na Figura 2.20(a) pode ser observado a segmentação (do fígado e dos rins) sobreposta a fatia original e na Figura 2.20(b) pode ser observada a vista anterior do fígado e dos rins do volume reconstruído tridimensionalmente.

Figura 2.20 – (a) Resultado da segmentação automática do fígado e dos rins. (b) Volume do fígado e rins segmentado reconstruído tridimensionalmente.




Fonte: [32].

No trabalho de ChangYang L. e seus colaboradores [33], também é utilizada metodologia baseada em atlas probabilístico para realizar a segmentação do fígado em imagens de TC. O atlas probabilístico (com volume e posição da estrutura) do fígado e da caixa torácica é construído de forma iterativa com dados do fígado segmentado manualmente, por especialista, e da caixa torácica segmentada automaticamente (baseado em função de limiarização e fluxo do vetor gradiente).

A segmentação do fígado ocorre pelo mapeamento do atlas probabilístico sobre o volume de entrada, verificando a probabilidade de cada voxel pertencer ao fígado. O resultado deste processo é aplicado numa função de distribuição de intensidade gaussiana para remover tecidos irrelevantes que tenham sido adicionados à região hepática, seguido de uma análise dos dados do atlas com a do fígado segmentado, para tentar preencher possíveis partes faltantes.

O conjunto de dados inicial foi de 40 exames (10 PET-CT de baixo contraste radiológico e 30 TC de alto contraste radiológico), destes, 25 (selecionados randomicamente) foram segmentados manualmente por radiologista para a construção do atlas e os 15 casos restantes foram usados para testar o desempenho da técnica de segmentação, obtendo assim 86,9% de taxa de acerto (4 exames) para os exames de baixo contraste radiológico e 92,8% de taxa de acerto (11 exames) para os exames com alto contraste radiológico (Figura 2.21). Com isso foi observado que a técnica está apta a segmentar exames com e sem contraste radiológico com bom desempenho.

Figura 2.21 – Resultado da segmentação do fígado em fatias com alto contraste radiológico.




Fonte: [33].

2.4 Segmentação baseada em outras técnicas

Na pesquisa de Foruzan A. H. e colaboradores [34] foi utilizado uma metodologia baseada em análise de intensidade, informação anatômica (localização das costelas e do fígado) e análise estatística para a segmentação do fígado em imagens de TC. A metodologia é baseada em algumas etapas: a primeira consiste em computar os parâmetros estatísticos do fígado (distribuição gaussiana, maximização da expectativa) na fatia com maior região hepática; Em seguida é proposta a definição de uma região de interesse ligando as costelas (Encontrar a região interna do abdome); Também é aplicado algoritmo para a remoção do coração (segmentação), uma vez que o mesmo costuma atrapalhar na segmentação do fígado; e para segmentar o fígado (é iniciada a segmentação da fatia central) é utilizado os valores do histograma da fatia (analisado visualmente) que corresponde ao fígado, para então aplicar a função de limiarização (utilizando os limites hepáticos) obtendo uma segmentação hepática. Através de comparação do fígado segmentado na fatia anterior (exceto na segmentação da fatia central que não tem segmentação hepática anterior) com a segmentação atual é aplicado a técnica de erosão morfológica, para estimar o contorno inicial do fígado.

Os resultados encontrados quando aplicada esta metodologia em 14 exames de TC, que foram capturados sem a aplicação de contraste radiológico, obteve média de 98,75% de acurácia com erro médio igual a 1,15%. Dessa forma foi observado boa segmentação do fígado (Figura 2.22) com esta metodologia.

Figura 2.22 – Resultado da segmentação hepática.




Fonte: [34].

No trabalho de Akram M. U., Aasia K. e Khalid I. [35] é proposta a segmentação automática do fígado em imagens de TC, porém com a aplicação de uma metodologia para deixar o algoritmo mais robusto para variações de tamanho, forma e valores de intensidades de níveis de cinza. A metodologia utiliza pré-processamento nas imagens com filtro de mediana e limiarização global para fazer a segmentação do fígado e operação morfológica de preenchimento, para preencher as falhas da função de limiarização, salvando a maior área 8-conectadas. Depois é realizado um pós-processamento com equalização de histograma, filtro gaussiano passa baixa e transformação de potência (Figura 2.23).

Esta metodologia foi aplicada em 100 imagens de TC de diferentes pacientes da região abdominal, alcançando a média de acurácia de 96%.

Figura 2.23 – Fígado segmentado pela técnica de [35].



Fonte: [35].


No trabalho desenvolvido pelos pesquisadores Shaohua S. e Yan S. [36] é apresentada uma metodologia automática de segmentação do fígado e de classificação de lesões com rede neural artificial em exames de TC multifase (fatias de fase arterial, fase portal e fase de equilíbrio).

A segmentação é realizada com algoritmo de *watershed* melhorado com processamento morfológico e não linear, para que a técnica seja menos sensível ao ruído. Para garantir que cada uma das fases tenha a mesma referência é aplicado a *Scale-invariant Feature Transform (SIFT)* nas fatias, e após a segmentação é utilizado o SIFT para finalizar o registro do fígado.

Já a detecção da área de interesse das lesões é realizada com a transformação *wavelet* de Gabor (Figura 2.24). E a extração de atributos para a classificação das lesões é realizada com informações de estatística de primeira ordem e segunda ordem de intensidades de níveis de cinza. A partir do *scattergram* é calculado os momentos e também são extraídos atributos temporais (Intensidade de sinal relativo, tendência da mudança de intensidade e taxa de melhoramento do sinal).

Os tecidos hepáticos são divididos em quatro grupos (tecido normal, cisto hepático, tecido cancerígeno, hemangioma), essa classificação é feita utilizando uma rede neural artificial.

Figura 2.24 – Resultado da segmentação hepática quando utilizado [36].




Fonte: [36].

Os autores Chartrand G. e seus colaboradores [37] propõem uma metodologia semiautomática (requer atividade do usuário na inicialização do algoritmo) para a segmentação do fígado utilizando modelo Laplaciano deformável (*Laplacian mesh*

optimization framework). Este modelo realiza iterações até convergir para a borda hepática e, por fim, é utilizada reconstrução volumétrica da segmentação.

Aplicando esta metodologia em 20 exames de TC, foram observados bons resultados (Figura 2.25) com baixo tempo de processamento (comparado com outras metodologias semelhantes), 6 minutos em média, e robustez na segmentação, com erro médio de 6,8%.

Figura 2.25 – Resultado da segmentação da metodologia [37].




Fonte: [37].

No trabalho de Heimann T. e colaboradores [38] foram avaliados 10 algoritmos e 6 métodos interativos para realizar a segmentação do fígado, todos estes algoritmos foram originados para o “*MICCAI 2007 Grand Challenge*”.

Por se tratar de vários tipos de algoritmos para a segmentação, foi desenvolvido um escore levando em conta vários fatores como tempo de segmentação, erro na segmentação, etc. Foi observado pelos pesquisadores que os três melhores métodos de segmentação automática foram baseados em modelos de morfologia estatística, e no caso da segmentação interativa (Figura 2.26), aproximadamente metade dos algoritmos tiveram escore por volta de 75%.

Os autores dizem que a segmentação automática do fígado está muito próxima da manual, e a tendência é que a segmentação automática seja melhor que a segmentação manual com o passar do tempo além de a maioria das técnicas testadas podem ser adaptadas para o uso clínico.

Figura 2.26 – Resultado da segmentação dos melhores resultados apresentados em [38].



Fonte: [38].

Capítulo 3 TOMOGRAFIA COMPUTADORIZADA DE FÍGADO

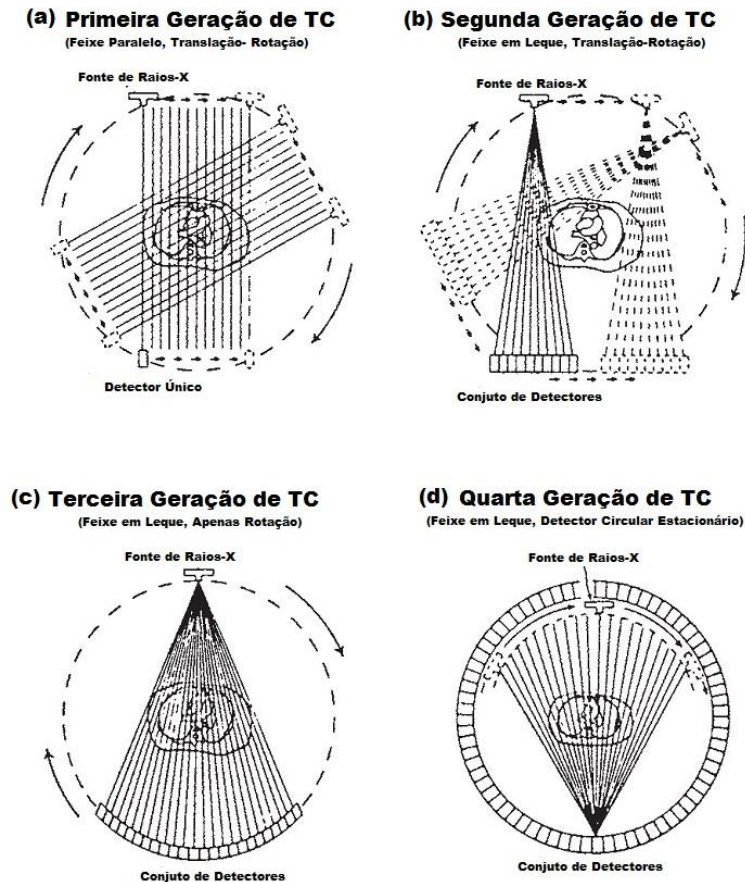
3.1 A Tomografia Computadorizada

A palavra Tomografia tem origem no idioma grego, onde “*Tomos*” significa corte ou fatia e “*Graphien*” tem o significado de escrita ou estudo, portando se pode dizer que tomografia é o estudo dos cortes. Na medicina a técnica de Tomografia Computadorizada é assistida por um computador, que gera as imagens (cortes) das estruturas internas do corpo humano a partir de uma série de sessões de área que são combinadas, gerando uma imagem reconstruída das estruturas internas do corpo [39].

O primeiro equipamento de Tomografia Computadorizada (TC) foi idealizado em 1971 por Sir Godfrey Newbold Hounsfield que o utilizou para visualizar imagens do cérebro, sendo o processo de captura e reconstrução da imagem demorava algo em torno de 25 minutos no caso deste órgão. A varredura do objeto neste tomógrafo acontecia pela translação do tubo de raios-X e do detector em conjunto, seguido de uma pequena rotação (Primeira geração de tomógrafos, Figura 3.1(a)) [39].

Em 1974 uma modificação na disposição dos detectores foi realizada, chamada de segunda geração de tomógrafos (Figura 3.1(b)), inserindo um conjunto detectores (posicionados lado a lado) e o tubo de raios-X passou a realizar emissão na forma de leque, captando assim um feixe de raios-X por vez, melhorando a velocidade da varredura. Na mesma época, outra forma de organização e funcionamento do tomógrafo foi alcançada, eliminando o movimento de translação e deixando apenas a rotação do tubo de raios-X e dos detectores, além de aumentar a quantidade de detectores (terceira geração, Figura 3.1(c)), aumentando ainda mais a velocidade e também a qualidade da imagem. Dois anos depois, em 1976, outra modificação foi proposta: nova organização do sistema detector-emissor, o que ficou conhecido como a quarta geração de tomógrafos (Figura 3.1(d)), sendo colocado o tubo de raios-X com movimento de rotação no interior de um anel fixo de detectores [39].

Figura 3.1 – As primeiras quatro gerações de tomógrafos, (a) Primeira Geração, (b) Segunda Geração, (c) Terceira Geração, (d) Quarta Geração.



Adaptado de [39].

O desenvolvimento da quinta geração de tomógrafos fez uma modificação considerável no design do equipamento, tornando o tubo de raios-X parte fixa do sistema, o direcionamento do feixe de elétrons é controlada eletronicamente por uma bobina de tungstênio, onde na parte inferior do *gantry* existe uma abertura por onde passa o feixe de raios-X e na parte superior do *gantry* estão localizados os sensores (de aquisição contínua de dados) e [39].

Buscando por uma tecnologia mais rápida para a digitalização das imagens, foi desenvolvido um sistema de rotação da ampola de raios-X com detectores fixos ou móveis e a captação de cortes acontece mesmo quando a mesa se encontra em movimento, por isso chamado essa tecnologia de sistema helicoidal, esta tecnologia já estava disponível para ser implantada a partir da 3-4 geração de tomógrafos [39].

3.2 A Geração da Imagem Tomográfica

A formação da imagem tomográfica utiliza uma ferramenta matemática conhecida por transformada de Radon [9, 40] que, a partir de retroprojeções dos senogramas, forma a fatia de TC como é conhecida.

3.2.1 Transformada de Radon

Inicialmente, pode-se dizer que a representação normal de uma linha reta que esta em coordenadas cartesianas é descrita da seguinte forma: $x\cos\theta + y\sin\theta = \rho$. E a projeção de um feixe de raios paralelos pode ser formada por um conjunto dessas linhas, onde um ponto arbitrário no sinal de projeção é dado pela soma de raios ao longo da linha $x\cos\theta_k + y\sin\theta_k = \rho_j$, essa soma de raios é uma integral de linha, dada conforme Equação (3.1) [9, 40].

$$g(\rho_j, \theta_k) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \delta(x\cos\theta_k + y\sin\theta_k - \rho_j) dx dy \quad (3.1)$$


Onde o lado direito da Equação (3.1) é igual a zero, a menos que o argumento de δ seja zero, ou seja, a integral é calculada ao longo da linha $x\cos\theta_k + y\sin\theta_k = \rho_j$. A Equação (3.1) pode ser generalizada quando considerado todos os valores de ρ e θ , conforme a Equação (3.2), que fornece a integral de linha de $f(x, y)$ ao longo da linha arbitrária no plano xy , que é a transformada de Radon [9, 40].

$$g(\rho, \theta) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \delta(x\cos\theta + y\sin\theta - \rho) dx dy \quad (3.2)$$

E no caso discreto a Equação (3.2) passa a ser igual à Equação (3.3), onde x , y , ρ e θ são variáveis discretas. Assim se for mantido o θ fixo, variando ρ ocorre a soma dos pixels de $f(x, y)$ na linha determinada dos valores destes dois parâmetros, modificando o θ e repetindo o procedimento anterior ocorre a formação de outra projeção. Realizando o procedimento descrito anteriormente para todo θ (variando de 0 a π) formam-se as projeções de $f(x, y)$ em todas as direções, conforme pode ser observado na Figura 3.2, onde na Figura 3.2(a) está a imagem de um retângulo enquanto na Figura 3.2(b) está a representação do senograma deste retângulo [9, 40].

$$g(\rho, \theta) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \delta(x \cos \theta + y \sin \theta - \rho) \quad (3.3)$$

Figura 3.2 – (a) Imagem de um retângulo medindo 30 unidades de área de lado e 50 unidades de área de altura. (b) Resultado do senograma do retângulo.



3.2.2 Formação da fatia de Tomografia Computadorizada

A imagem de tomografia computadorizada é reconstruída, baseado no que foi captado pelos sensores. As intensidades de raios-X (transmitidas através do corpo) que chegam aos sensores dependem do grau de atenuação sofrido, devido ao número atômico médio e energia do espectro de raios-X e também da densidade de massa dos tecidos do paciente, ou seja, a intensidade dos raios-X é atenuada por absorção e processo de espalhamento quando passa através do paciente [41].

O cálculo da intensidade transmitida é feito com a Equação (3.4), onde I_0 corresponde à intensidade do feixe incidente, I_t à intensidade do feixe transmitido, L é a espessura do objeto e $\mu(x)$ corresponde ao coeficiente de atenuação linear dos raios-X (variando de acordo com o tipo do tecido). A atenuação linear dos raios-X é medida através de uma conversão linear da atenuação medida, na escala de Hounsfield, ou do inglês *Hounsfield Scale (HU)*. Esta escala considera a densidade da água como sendo igual a 0 HU e a do ar igual a -1000 HU, com isso consegue-se chegar ao valor correspondente em HU de qualquer tecido [41].

$$I_t = I_0 e^{-\int_0^L \mu(x) dx} \quad (3.4)$$

Conhecendo a intensidade transmitida é possível fazer a reconstrução dos dados capturados pelo sensor presente no equipamento de tomografia computadorizada utilizando a

transformada de Radon para fazer o senograma (projeções), e a partir da soma das retroprojeções gerar uma fatia de TC [8, 9].

A equação de uma imagem retroprojetada da transformada de Radon pode ser observada na Equação (3.5) onde, considerando um único ponto, $g(p_j, \theta_k)$ da projeção completa, para um valor fixo de θ_k , uma parte da imagem consiste em copiar uma linha $L(p_j, \theta_k)$ da imagem onde cada ponto desta linha equivale a $g(p_j, \theta_k)$. Repetindo esse procedimento para todos os valores de p_j no sinal projetado para um valor arbitrário de θ_k , forma-se uma única retroprojeção de um ângulo θ [8, 9].


$$f_{\theta}(x, y) = g(x \cos \theta + y \sin \theta, \theta) \quad (3.5)$$

A imagem final é formada pela integração de todas as imagens retroprojetadas, ou no caso discreto, pelo somatório destas imagens retroprojetadas, conforme pode ser observado pela Equação (3.6) [8, 9].

$$f(x, y) = \sum_{\theta=0}^{\pi} f_{\theta}(x, y) \quad (3.6)$$

Estas equações e discussões foram baseadas para o feixe de raios-X paralelo e nos equipamentos mais modernos geralmente utilizam a geometria de aquisição de imagens em formato de leque ou cone (Figura 3.3), o que leva, conseqüentemente, a modificações na fórmula de cálculo das projeções e retroprojeções para a formação da fatia [8, 9].


Figura 3.3 – Exemplo da disposição dos feixes de raios-X, (a) feixe paralelo, (b) feixe em leque e (c) feixe em cone.



Adaptado de [36].

Portanto, a imagem da TC é uma representação tridimensional de um volume a partir de suas projeções, por onde se realiza retroprojeções de cada projeção e depois se faz a soma de todas as retroprojeções para gerar uma imagem (fatia). A imagem de um corte (fatia) de tomografia computadorizada pode ser observada na Figura 3.4 [8, 9].

Figura 3.4 – Exemplo de imagem de tomografia computadorizada.



3.3 O padrão DICOM

O padrão DICOM, que é a abreviação de “*Digital Imaging and Communications in Medicine*” e é um conjunto de protocolos para serem utilizados nas imagens digitais em saúde. Foi criado com o objetivo de padronizar os protocolos de imagens digitais médicas, inclusive faz parte da ISO 12052 (“*Health Informatics*”) [42], sem levar em consideração qual é o fabricante do equipamento, visando a interconectividade de sistemas e expansão dos sistemas “*Picture Archiving and Communication Systems – PACS*” (Sistema de arquivamento e comunicação voltado ao diagnóstico por imagem).

O padrão DICOM é administrado pelo “*National Electrical Manufacturers Association – NEMA*” que é um comitê composto por fabricantes de equipamentos por imagem e instituições médico-científicas [43, 44].

O padrão DICOM é um encapsulamento entre uma imagem digital (compactadas em jpeg ou tiff) e um cabeçalho com informações uteis. No cabeçalho das imagens de tomografia computadorizada analisadas existem 132 códigos (*tags*) diferentes, sendo que algumas destas

informações disponibilizadas são úteis para o processamento das imagens. Na Tabela 3.1 é apresentada uma lista do cabeçalho com os itens mais relevantes para este trabalho.

Tabela 3.1 – Exemplo de algumas *tags* do cabeçalho DICOM.

Número	Nome	Significado
(0008,0008)	Image Type	Identificação das características da imagem.
(0008,0060)	Modality	Especifica qual tipo é a imagem, ex. “CT”.
(0008,0070)	Manufacturer	Fabricante do equipamento.
(0008,1090)	Manufacturer's Model Name	Modelo do equipamento.
(0018,0010)	Contrast/Bolus Agent	Fármaco utilizado no contraste radiológico.
(0018,0015)	Body Part Examined	Parte do corpo examinada.
(0028,0100)	Bits Allocated	Número de bits alocados para cada amostra de pixel na fatia.
(0028,0101)	Bits Stored	Número de pixels armazenados para cada amostra de pixel na fatia.
(0028,0102)	High Bit	Pixel mais significativo na amostra de dados dos pixels.
(0028,1050)	Window Center	Define o centro da janela para exibição.
(0028,1051)	Window Width	Define o tamanho da janela para exibição.
(0028,0030)	Pixel Spacing	Distância física entre os pixels na fatia em milímetro.
(0018,9311)	CT Pitch Factor	Relação entre o avanço da mesa por rotação.

Fonte: [45, 46].

Assim, a visualização da imagem de tomografia computadorizada é apenas uma das informações que podem ser recuperadas, pois no arquivo de tomografia computadorizada também tem um cabeçalho com várias informações que são importantes na tomografia computadorizada.


3.4 O Fígado e sua imagem tomográfica

3.4.1 Fígado

O fígado é o maior órgão do corpo humano, além de ser a víscera mais volumosa do abdome, contribuindo com aproximadamente 2% do peso total do corpo. E está localizado na região superior do abdome (abaixo do diafragma), ficando mais a direita da cavidade abdominal, onde dois terços de seu volume ficam na porção direita da linha mediana do corpo e um terço na porção esquerda da linha mediana do corpo humano [7].

Através de sua anatomia, o fígado é subdividido em lobos (essa divisão é baseada na irrigação da veia porta hepática e artéria hepática), sendo estes presentes em sua face diafragmática (lobo direito, lobo esquerdo) Figura 3.5(a) e visceral (lobo direito, lobo esquerdo, lobo quadrado e lobo caudado) Figura 3.5(b) [7].

Figura 3.5 – (a) Face diafragmática do fígado. (b) Face visceral do fígado.



Fonte: [47].

O fígado atua na produção de bile (que fica armazenada na vesícula biliar), que é utilizada para digerir as gorduras que entram no duodeno. Ele também atua no metabolismo de carboidratos, lipídios e proteínas, absorção de fármacos e hormônios, fagócitos, armazena glicose, sangue (até 10% do volume total de sangue no corpo), ferro, cobre e vitaminas. Pelo seu grande papel no metabolismo do corpo, ele é considerado um órgão vital, sendo

necessário de pelo menos um terço dele em funcionamento, também é o único órgão do corpo humano capaz de regenerar até 75% de seu tecido [7, 47].

Devido a regeneração hepática é passível de acontecer doação de fígado a partir de doadores vivos. Porém, para garantir a segurança do doador, no caso de doação do lobo direito, é necessário que o volume remanescente do lobo direito, após a cirurgia, seja superior a 35% considerando de acordo com Guyton A. C. e Hall J. E. [7], onde foi constatado que os pacientes que tiveram o volume remanescente do lobo direito inferior a 35% apresentaram mais dificuldade de regeneração hepática, inclusive necessitando de cuidados intensivos [7].

Para o planejamento das cirurgias do fígado, podem ser utilizadas algumas ferramentas de auxílio computacional, como a desenvolvida por Yen-Wei C. [12], onde a partir de exames de TC do paciente, o cirurgião pode realizar uma simulação e planejamento da cirurgia hepática a ser realizada.

3.4.2 Imagem tomográfica de fígado

O exame de TC do fígado é comumente utilizado para diagnosticar e analisar as patologias hepáticas. Nas imagens de TC hepática, o parênquima hepático possui uma faixa de atenuação de raios-X específica, conforme a constituição e disposição das células, e essa atenuação dos raios-X para fígado está na faixa de 40 a 70 HU[48].


Em alguns casos é utilizado o contraste radiológico intravenoso para a execução do exame de TC, e nestes casos são capturadas as fatias hepáticas em três fases distintas, relacionadas com o espaço de tempo em que foi adicionado o contraste radiológico [48]:

- Fase Arterial (Vascular) -> A captura de fatias de TC do fígado ocorre 12 segundos após a administração intravenosa do contraste radiológico;
- Fase Portal (arterio-portal) -> A captura de fatias de TC do fígado ocorre no período de 30 a 60 segundos após a administração intravenosa do contraste radiológico;
- Fase de Equilíbrio -> A captura de fatias de TC do fígado ocorre de 110 a 120 segundos após a administração intravenosa do contraste radiológico.

A administração do contraste radiológico provoca nas imagens de TC um acréscimo de 50 HU no fígado, a fase arterial é caracterizada pelo rápido aumento aórtico da intensidade de nível de cinza da fatia, devido à artéria hepática. Já nas fatias que se encontram na fase portal, ocorre realce do parênquima hepático e dos ramos da veia portal. Nas fatias que se encontram na fase de equilíbrio, o contraste da imagem diminui, voltando a ficar próximo ao contraste de nível de cinza do parênquima hepático sem a aplicação do contraste radiológico. Na Figura

3.6 é apresentando a dinâmica da evolução do realce de contraste de níveis de cinza do fígado ao longo do tempo, onde a linha mais espessa representa o realce do nível de intensidade que acontece na artéria aorta e a linha menos espessa representa o realce do nível de intensidade de cinza que o parênquima hepático está sujeito nas três fases de aquisição de imagens [48].


Figura 3.6 – Melhoria de intensidade de nível de cinza quando aplicado contraste radiológico no fígado onde (a) representa a fase arterial, (b) representa a fase portal e (c) representa a fase de equilíbrio.



Adaptado de [48].

Então, para exemplificação, na Figura 3.7(a) é inserida uma fatia sem realce de contraste, na Figura 3.7(b), (c) e (d) pode ser observado a mesma fatia na fase arterial, fase portal e fase de equilíbrio, respectivamente.

Figura 3.7 – Fatia de TC de fígado (a) sem contraste radiológico, (b) fase arterial, (c) fase portal e (d) fase de equilíbrio.



Adaptado de [49].

Capítulo 4 TÉCNICAS DE PRÉ-PROCESSAMENTO

Este capítulo trata da teoria das técnicas de pré-processamento que serão utilizadas, com a intenção de remoção de ruídos e aguçamento dos detalhes das fatias de Tomografia Computadorizada (TC) da região abdominal.

O processo de digitalização e transmissão pode gerar ruídos na imagem digital, por exemplo, devido à limitação dos detectores do equipamento de TC ou a utilização incorreta dos parâmetros de tensão e corrente na geração dos raios-X, resultando num contraste insuficiente (ou excessivo) para a visualização de seus detalhes. Em ambos os casos é necessário realizar pré-processamento para visualização de detalhes e processamento digital das imagens [8, 9, 50].

4.1 Filtros de Suavização e Aguçamento

4.1.1 Filtro de Média Aritmética

O filtro de média aritmética é um filtro espacial de suavização utilizado para reduzir ruído aleatório nas imagens. Seu funcionamento consiste em substituir o valor de cada pixel de uma imagem pela média dos níveis de cinza de sua vizinhança, resultando na remoção das transições abruptas dos pixels. [9, 50]

A forma de cálculo deste filtro é observada através da Equação (4.1, onde o S_{xy} é uma subimagem de tamanho $[m \ n]$ com centro no ponto (x,y) , o $g(s,t)$ é a porção da imagem original definida pela região S_{xy} e por fim Sub_{Im} é a porção da imagem filtrada no ponto (x,y) .

$$Sub_{Im}(x, y) = \frac{1}{mn} * \sum_{(s,t) \in S_{xy}} g(s, t) \quad (4.1)$$

Porém, a aplicação desse filtro deve ser com cautela, uma vez que pode resultar na perda da nitidez na imagem e também borrar as bordas, já que elas são transições abruptas de níveis de cinza.

4.1.2 Filtro de Média Geométrica

O filtro de média geométrica é um filtro de suavização utilizado para a remoção de ruídos, tendo seu resultado semelhante ao filtro de média aritmética (seção 4.1.1 Filtro de Média Aritmética), porém tende a perder menos detalhes, dependendo do tipo de ruído e da imagem a ser filtrada [9, 50].

O cálculo deste filtro pode ser representado através da Equação (4.2), sendo definida uma subimagem (S_{xy}) com o tamanho $[m \ n]$ com o centro definido no ponto (x,y) , já o $g(s,t)$ é uma porção da imagem original de mesmo tamanho de S_{xy} e a Sub_{im} a porção da imagem em que foi aplicado o filtro de média geométrica no ponto (x,y) .

$$Sub_{im}(x,y) = \left[\prod_{(s,t) \in S_{xy}} g(s,t) \right]^{\frac{1}{mn}} \quad (4.2)$$

Os pixels resultantes do processo de filtragem são determinados pelo produto desses pixels na janela da subimagem, elevado à potência de “ $1/mn$ ”.

4.1.3 Filtro de Mediana

O filtro de mediana é um tipo de filtro não linear (Filtro de Estatística de Ordem) onde a resposta do filtro está relacionada à ordenação dos pixels da fatia que estão na área coberta pelo filtro, substituindo o valor do pixel central pelo resultado da classificação, nesse caso pelo valor da mediana da vizinhança deste pixel [9, 50]. Para alguns tipos de ruídos aleatórios o filtro de mediana possui uma resposta satisfatória, borrando menos as bordas que nos filtros lineares de suavização.

4.1.4 Filtro de Wiener

O filtro de Wiener também é conhecido como filtro de mínimo erro quadrático médio, sendo geralmente aplicado quando está presente o ruído do tipo quântico. Este filtro considera que o ruído e a imagem são variáveis aleatórias no domínio da frequência espacial, sendo o seu objetivo eliminar e restaurar a degradação da imagem por este tipo de ruído, através da estimativa da imagem não corrompida, onde o erro quadrático médio seja mínimo. Este filtro assume que a imagem e o ruído não são correlacionados, onde um dos dois possua média

zero, além de que, os níveis de intensidade do nível de cinza assumidos pela intensidade estimada sejam uma função linear dos níveis de cinza da imagem degradada [9, 50, 51].

O algoritmo utilizado deste filtro usa a média e o desvio padrão, estimados a partir da vizinhança do pixel, além de considerar que o ruído presente na imagem é do tipo gaussiano (se este ruído não estiver disponível, é utilizada a média de todas as variâncias locais estimadas). A equação do filtro de Wiener é dada pela Equação (4.3).

$$\begin{aligned}\mu &= \frac{1}{MN} \sum_{n_1, n_2 \in \eta} Im(n_1, n_2) \\ \sigma^2 &= \frac{1}{MN} \sum_{n_1, n_2 \in \eta} Im^2(n_1, n_2) - \mu^2 \\ b(n_1, n_2) &= \mu + \frac{\sigma^2 - v^2}{\sigma^2} (Im(n_1, n_2) - \mu)\end{aligned}\tag{4.3}$$

Onde:

- Im é a imagem a ser aplicado o filtro de Wiener;
- μ é a média estimada ao redor do pixel da imagem Im ;
- σ^2 é a variância estimada ao redor do pixel da imagem Im ;
- v^2 é a variância do ruído;
- MN é a vizinhança ao redor do pixel da imagem Im .

4.1.5 Operador Laplaciano

O operador laplaciano é um tipo de filtro espacial sendo comumente utilizado para fazer aguçamento de bordas e é obtido da derivada de segunda ordem do valor da função que descreve o nível de intensidade dos pixels, sendo considerado um tipo de filtro isotrópico, ou seja, a resposta independe de quais as direções das descontinuidades da imagem, a qual é aplicada o filtro. A função que representa o operador laplaciano (na forma discreta) pode ser observada na Equação (4.4). [9, 50]

$$\nabla^2 f = (f(x+1, y) + f(x-1, y) + f(x, y+1) + f(x, y-1) - 4f(x, y))\tag{4.4}$$

Onde:

- $\nabla^2 f$ equivale a saída do operador derivativo de segunda ordem (máscara);
- $f(x, y)$ são as coordenadas da matriz da máscara do operador laplaciano.

A máscara que foi calculada pela Equação (4.4) para ser utilizada no processamento pode ser observada na Figura 4.1. Este tipo de máscara gera resultados isotrópicos em incrementos de 45°.

Figura 4.1 – Máscara do operador Laplaciano com centro negativo.

$$\begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

4.1.6 Operadores de Sobel

Os operadores de Sobel são considerados também como filtro espacial para aguçamento de bordas e a máscara deste filtro é originada através da aproximação discreta do gradiente das derivadas de primeira ordem. A equação que da origem a estas máscaras é dada pela Equação (4.5) [9, 50].

$$\text{Sendo a notação da máscara igual à } \begin{bmatrix} z_1 & z_2 & z_3 \\ z_4 & z_5 & z_6 \\ z_7 & z_8 & z_9 \end{bmatrix}$$

$$\nabla f \equiv \text{grad}(f) \equiv \begin{bmatrix} g_x \\ g_y \end{bmatrix}$$

(4.5)

$$\begin{cases} g_x = \frac{\partial f}{\partial x} = (z_7 + 2z_8 + z_9) - (z_1 + 2z_2 + z_3) \\ g_y = \frac{\partial f}{\partial y} = (z_3 + 2z_6 + z_9) - (z_1 + 2z_4 + z_7) \end{cases}$$

Onde:

- ∇f equivale ao gradiente de $f(x,y)$;
- g_x é a aproximação discreta da derivada parcial do gradiente na direção x;
- g_y é a aproximação discreta da derivada parcial do gradiente na direção y;

Assim, este filtro é definido por duas máscaras para serem aplicadas na imagem, originadas a partir da Equação (4.5), uma para realçar as bordas horizontais (Figura 4.2(a)) e outra para realçar as bordas verticais (Figura 4.2(b)).

Figura 4.2 – (a) Operador de Sobel Horizontal, (b) Operador de Sobel Vertical.

$$\begin{matrix} \text{(a)} \\ \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \end{matrix}$$


$$\begin{matrix} \text{(b)} \\ \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \end{matrix}$$

4.2 Transformação de intensidade

4.2.1 Transformação Logarítmica

A transformação logarítmica é uma função de modificação da intensidade com o objetivo de realizar o realce da imagem, fazendo a transformação pixel a pixel, podendo realizar uma compressão dos níveis de cinza, conforme pode ser observada na Figura 4.3. A forma geral do cálculo da transformação logarítmica é dada pela Equação (4.6) [9, 50].

Figura 4.3 – Gráfico do comportamento da transformação logarítmica.



Adaptado [9].

$$s = c * \log(1 + r) \quad (4.6)$$

Onde:

- s é o nível de intensidade do pixel de saída;
- c é a constante de deslocamento;
- r é o nível de intensidade do pixel de entrada.

4.2.2 Transformação Exponencial

A transformação exponencial é uma transformação que realiza transformação de intensidade de nível de cinza pixel a pixel, comprimindo os valores dos pixels mais escuros ao mesmo tempo em que expande os níveis de cinza mais alto. A forma geral de cálculo da transformação exponencial pode ser observada na Equação (4.7) [9, 50].

$$s = e^{\left(\frac{r}{c}\right)} - 1 \quad (4.7)$$


Onde:

- s é o nível de intensidade do pixel de saída;
- c é a constante de deslocamento;
- r é o nível de intensidade do pixel de entrada.

4.2.3 Transformação de Potência (Gama)

A transformação de Potência, ou como é mais conhecida “transformação gama”, realiza manipulação de contraste na imagem mapeando uma faixa estreita de valores escuros de entradas em uma faixa mais ampla de valores de saída. Quando utilizado valores para γ (fator gama) menores do que “1”, ou seja, deixando a imagem mais clara o oposto é observado para valores maiores do que “1”. Podendo ser observado algumas curvas da resposta da técnica na Figura 4.4 [9, 50].

Figura 4.4 – Gráfico do comportamento da transformação de potência.



Adaptado [9].


Esta transformação gama pode ser calculada conforme apresentado na Equação (4.8), sendo que s representa o nível de intensidade do pixel da imagem de saída, c é a constante de deslocamento, r é o nível de intensidade do pixel de entrada e por fim γ é o fator de correção gama a ser aplicado na imagem.

$$s = c * r^\gamma \quad (4.8)$$

4.2.4 Transformação Alargamento de Contraste

Esta é uma transformação de intensidade de pixels por função linear definida por partes (Figura 4.5), que expande os níveis de intensidade da fatia, do intervalo de nível de cinza de interesse, realizando um aumento da escala dinâmica dos níveis de cinza na imagem [9, 50].

Figura 4.5 – Forma geral da função de alargamento de contraste.



Adaptado [9].

A função da transformação de alargamento de contraste deve ser univariada e monotonicamente crescente, ou seja, “ $r_1 \leq r_2$ ” e “ $s_1 \leq s_2$ ” para que não sejam criados artefatos na intensidade da imagem processada.

Capítulo 5 TÉCNICAS DE SEGMENTAÇÃO BASEADA EM REGIÃO

O cérebro humano, rapidamente reconhece os diferentes objetos numa imagem que esta sendo observado pelos olhos, porém, no caso dos sistemas computacionais, para reconhecer os objetos e estruturas presentes é necessário um algoritmo para analisar a sequência e valores dos pixels presentes na imagem e só então tomar uma decisão sobre quais os objetos presentes na imagem. Geralmente esta análise computacional se inicia pela segmentação dos diferentes objetos presentes na imagem [52].

Assim, na área da saúde, os médicos radiologistas analisam cuidadosamente as imagens radiográficas a procura de anormalidades, um processo cansativo e que pode levar muito tempo. Quando o médico encontra uma região com suspeita de anormalidades, ele se concentra nesta região, examinando as suas características, procurando por padrões para decidir se realmente a imagem demonstra algum sinal particular de doença no paciente [52].

Para auxiliar os médicos radiologistas no diagnóstico de patologias surgiram os sistemas de diagnóstico auxiliado por computador, ou do inglês *Computer Aided Diagnosis* – CAD sendo desenvolvido para tipos específicos de exames diagnósticos por imagens. O CAD realiza processamento nas imagens, detectando regiões de interesse e ainda classificando estas regiões de interesse em várias categorias para então mostrar um alerta ao médico caso seja detectado algum padrão que indica uma patologia [52].

Desta maneira, a segmentação de imagens é uma das partes fundamentais do CAD, uma vez que as técnicas de segmentação de imagens são responsáveis pela divisão das imagens em regiões de interesse para que, então, sejam realizados a classificação ou reconhecimento dos objetos presentes na imagem [52]. A segmentação é considerada uma das tarefas mais difíceis no processamento de imagens, onde a precisão da segmentação determina o sucesso ou fracasso dos processos de análise computadorizada [9].

A segmentação pode ser definida como o processo de separação das imagens em regiões com atributos similares. O atributo mais básico para a segmentação numa imagem é a amplitude da luminância para imagens monocromáticas, as bordas e texturas também são atributos uteis para a segmentação.

Como não existe uma única teoria de segmentação de imagens, surgiram várias técnicas de segmentação de imagens, como a limiarização, aplicável em imagens que possuam valores de intensidade de pixel que possam ser agrupados em dois grupos, ou mesmo a técnica de agrupamento que, baseado em medidas de atributos na imagem (como média móvel, desvio padrão, moda), faz o agrupamento de pixels que tenham atributos similares, e também a técnica baseada em bordas que procura por variações abruptas de intensidade na imagem para fazer a segmentação das regiões [53].

Além destas técnicas citadas no parágrafo anterior, também existe a técnica de segmentação baseada em região (tema abordado neste capítulo) que utiliza propriedades geométricas para juntar pixels com propriedades semelhantes, entretanto, a eficiência da técnica é altamente dependente da seleção do ponto de semente [54].

A segmentação baseada em região utiliza o conhecimento de que uma vizinhança possui pixels com características (valores) semelhantes, desde que não sejam bordas, podendo ser dividido em três grupos: divisão e fusão de região, “watershed” e crescimento de região [9].

5.1 Técnica de segmentação baseada em divisão e fusão de região

A técnica de segmentação baseada em divisão e fusão de região, inicialmente divide a imagem num conjunto arbitrário de regiões desconexas e, então, realiza a fusão ou uma nova divisão a fim de satisfazer uma condição de segmentação (por exemplo, todos os pixels da região devem possuir o mesmo nível de intensidade) que foi definida previamente.

Para melhor entendimento desta técnica de segmentação será definidas algumas propriedades da segmentação numa imagem. Sendo R uma região espacial ocupada por uma imagem, a segmentação realiza o particionamento de R em n sub-regiões R_1, R_2, \dots, R_n devendo satisfazer as condições definidas no Quadro 5.1 [9]:

Quadro 5.1 – Propriedades da segmentação.

- (a) $R = \bigcup_{i=1}^n R_i$;
- (b) R_i é um conjunto conectado, onde $i=1, 2, 3, \dots, n$;
- (c) $R_i \cap R_j = \emptyset$ para todo i e $j, i \neq j$;
- (d) $Q(R_i) = VERDADEIRA$ para $i=1, 2, 3, \dots, n$;
- (e) $Q(R_i \cap R_j) = FALSA$ para quaisquer regiões adjacentes R_i e R_j .

Onde a condição (a) do Quadro 5.1 significa que a segmentação deve ser completa, ou seja, cada pixel deve pertencer a alguma região na segmentação. A condição (b) do Quadro


5.1 requer que os pixels de uma região estejam conectados de alguma forma predefinida (por exemplo, 4-conectados ou 8-conectados). A condição (c) do Quadro 5.1 indica que as regiões devem estar separadas. Já a condição (d) do Quadro 5.1 se refere à propriedade que deve ser satisfeita pelos pixels pertencentes à região segmentada, por exemplo, $Q(R_i) = \text{VERDADEIRA}$ se todos os pixels em R_i tiverem o mesmo nível de intensidade. A condição (e) do Quadro 5.1 requer que duas regiões adjacentes, R_i e R_j possuam propriedades Q diferentes.

A forma geral para realizar o procedimento de segmentação pela técnica de divisão / fusão, é a seguinte:

- Definir *condição inicial* de semelhança da região, por exemplo, o desvio padrão da região deve ser maior que o desvio padrão do fundo;
- Assumindo que a imagem é quadrada, subdividir toda a imagem sucessivamente em regiões quadradas (quadrantes), cada vez menores até que a região seja homogênea;
 - Fazer iterações do processo de divisão enquanto $Q(R_i) = \text{FALSO}$;
- Não sendo possível continuar dividindo as regiões, unir as regiões adjacentes R_j e R_k onde $Q(R_i \cup R_j) = \text{VERDADE}$;
- Parar quando não for possível realizar mais fusões.

Na Figura 5.1(a) pode ser observado uma representação de imagem com suas respectivas sub-regiões, enquanto na Figura 5.1(b) pode ser observado essa mesma imagem na representação conhecida como *Quadtree* [9].

Figura 5.1 – (a) Representação da imagem com as sub-regiões. (b) *Quadtree* representando a imagem completa.




Adaptado de [9].

5.2 Técnica de segmentação baseada em topografia e hidrografia

Esta técnica utiliza conceitos de topografia e hidrografia, e se considerando uma imagem monocromática, sendo representada em altitude, o pixel de valor alto corresponde a um cume, enquanto um pixel de baixa amplitude corresponde a um vale. Dessa forma se caísse água sobre esta imagem, os pixels de valores baixos seriam preenchidos pela acumulação da água (chamado de charco ou barragem). Todos os pontos que são preenchidos pelo charco fazem parte da mesma bacia hidrográfica ou do inglês *watershed* (que dá o nome a esta técnica), enquanto o cume representa o gradiente máximo em altura desta superfície. Na Figura 5.2 é observado uma representação do funcionamento desta técnica [9].

Figura 5.2 – Representação de funcionamento da técnica de watershed.




Adaptado de [55].

Há duas formas básicas para calcular computacionalmente as regiões por *watershed* numa imagem, a técnica por *rainfall* e a técnica conhecida por *flooding*.

Pelo algoritmo de *rainfall* os mínimos locais são encontrados em toda a imagem, em cada um desses mínimos é dado um marcador único, e quando são adjacentes locais eles são combinados. Em sequência, em cada pixel não marcado é colocado uma gota de água, essa gota se move para o seu vizinho de menor amplitude até que alcance um pixel marcado, assumindo o valor dessa marcação, conforme a Figura 5.3 [9, 56].


Figura 5.3 – Representação da movimentação de uma gota de água para o mínimo regional.



Adaptado de [53].

E pela técnica *flooding* (inundação), que considerando a imagem de entrada visualizada na forma topográfica, a intenção é produzir linhas de divisão de água nesta superfície. A água entra através de furos, feitos em cada mínimo regional, e a amplitude da superfície é reduzida a um grande corpo de água. A água entra pelos orifícios para preencher cada bacia hidrográfica a uma taxa constante. Se a bacia está preste a transbordar (águas vindas de diferentes mínimos regionais estão prestes a se encontrar) é construída uma represa conceitual (Barreira) sobre a linha do cume em questão até que a altura seja igual ao ponto mais alto de seu cume, conforme representação apresentada na Figura 5.4. Com a passagem do tempo é visível apenas os topos das barreiras que estão visíveis acima do nível da água, que são as linhas correspondentes a *watershed* [53, 57].

Figura 5.4 – Representação de uma barragem construída.



Adaptado de [53].

Assim, considerando $f: D \rightarrow \mathbb{N}$ como sendo uma imagem digital em escala cinza, o menor valor da intensidade de nível de cinza para a imagem é chamado de h_{min} e o seu maior valor da intensidade de nível de cinza é chamado de h_{max} . Então, para realizar o cálculo da *watershed* com a teoria de *flooding* é variado recursivamente a intensidade de nível de cinza h de h_{min} até h_{max} , onde as bacias com o mínimo de f são expandidas sucessivamente, sendo X_h a união de um conjunto de bacias pertencentes a mesma intensidade de nível de cinza h . E um componente conectado ao limiar definido como T_{h+1} na intensidade de nível de cinza $h+1$ pode ser um novo mínimo ou uma extensão da bacia X_h , sendo feito o cálculo da zona de influência de X_h sobre T_{h+1} , e a união de todos os mínimos regionais da intensidade do nível de cinza h é denominada de MIN_h , conforme Equação (5.1). Desta forma o resultado da *watershed* ($Wshed(f)$) de f é o complemento de $X_{h_{max}}$ em D , ou seja, $Wshed(f) = D \setminus X_{h_{max}}$ [57].

$$\begin{cases} H_{h_{min}} = \{p \in D | f(p) = h_{min}\} = T_{h_{min}} \\ X_{h_1} = MIN_{h+1} \cup IZ_{T_{h+1}}(X_h), \quad h \in [h_{min}, h_{max}] \end{cases} \quad (5.1)$$

5.3 Técnica de segmentação baseada em crescimento de região

A técnica de crescimento de região agrupa os pixels numa região, iniciando a partir do pixel de semente (ou pequeno conjunto de pixels), e cresce espacialmente a partir da verificação da conectividade de pixels segundo critério de similaridade [9, 52].

Considerando que R seja uma representação espacial da imagem, a segmentação pode ser considerada como sendo a divisão de R em n sub-regiões (R_1, R_2, \dots, R_n). E se realizado $\cup_{i=1}^n R_i$, esta união deve resultar em R , ou seja, todo pixel deve pertencer a uma região [9, 52].

Um algoritmo genérico para o crescimento de região baseado no agrupamento dos pixels similares pode ser observado na sequência [9, 52]:

- Inicie com o ponto de semente (ou um conjunto de pixels);
- Acrescente os pixels que possuem propriedades semelhantes (nível de cinza, cor) ao ponto de semente verificando vizinhança 4-conectados ou 8-conectados;
- Pare quando não houver mais pixels semelhantes na vizinhança (4-conectado ou 8-conectado).

O resultado deste algoritmo é altamente dependente do local de lançamento do ponto de semente e também de como é realizado a medida de similaridade entre os pixels. A forma de medir a similaridade é através da escolha de um valor de limite máximo da diferença absoluta entre o valor de intensidade do ponto de semente e o valor da intensidade do pixel que está sendo analisado no momento [9, 52].

Outro modo de medir a similaridade é através da comparação com a técnica conhecida por nível de tolerância aditiva, ou do termo na língua inglesa *additive tolerance level*, que permite variação entre as diferenças absolutas dos níveis de cinza da vizinhança. Para isso, utiliza-se a média de intensidade de pixels da região ao invés de se utilizar somente o valor de intensidade do ponto de semente para realizar a comparação. Sendo T o nível de tolerância admitido (ou seja, compreende a máxima variação de intensidade entre pixels vizinhos admitidos), $f(m,n)$ o valor do pixel da imagem na posição (m,n) , μ_{R_c} a média da região R_c , N_c a quantidade de pixels presentes na região R_c a equação que representa a comparação para o nível de tolerância pode ser observada a seguir, na Equação (5.2 [9, 52]:

$$|f(m, n) - \mu_{Rc}| \leq T \quad (5.2)$$

Onde,

$$\mu_{Rc} = \frac{1}{N_c} \sum_{(m,n) \in R_c} f(m, n)$$

A Figura 5.3.1 mostra um exemplo de aplicação das duas formas de comparação de similaridade, considerando que o nível de tolerância admitido seja $T=3$ e que a imagem possui tamanho $[5 \times 5]$ (Figura 5.5(a)). Na Figura 5.5(b) é observado a segmentação, caso o ponto de semente esteja na posição $(2,2)$, que nesse caso, é a melhor localização para o ponto de semente. Porém, se o ponto de semente for definido na posição $(3,3)$ (Figura 5.5(c)), utilizando a comparação do nível de intensidade do ponto de semente com os valores dos pixels da vizinhança, dois pixels não são considerados como sendo similares, e assim não são adicionados à região. Já a Figura 5.5(d) mostra um exemplo da aplicação do nível de tolerância aditiva em que independente de qual dos pixels da região seja considerado como ponto de semente, é segmentado toda a região.

Figura 5.5 – Em (a) está a imagem original. (b) Segmentação por crescimento de região (Área escura) com ponto de semente em (2,2). (c) Segmentação por crescimento de região (Área escura) alterando o ponto de semente para (3,3) utilizando tolerância convencional ($|f(m,n)| \leq T$). (d) Resultado da segmentação por crescimento de região (Área escura) utilizando a técnica de nível de tolerância aditiva.

(a)						(b)					
	1	2	3	4	5		1	2	3	4	5
1	100	101	101	100	101	1	100	101	101	100	101
2	100	127	126	128	100	2	100	seed	126	128	100
3	100	124	128	127	100	3	100	124	128	127	100
4	100	124	125	126	101	4	100	124	125	126	101
5	101	100	100	101	102	5	101	100	100	101	102

(c)						(d)					
	1	2	3	4	5		1	2	3	4	5
1	100	101	101	100	101	1	100	101	101	100	101
2	100	127	126	128	100	2	100	127	126	128	100
3	100	124	seed	127	100	3	100	124	128	127	100
4	100	124	125	126	101	4	100	124	125	126	101
5	101	100	100	101	102	5	101	100	100	101	102

Adaptado de [52].

Para tornar ainda menos sensível o resultado da segmentação ao valor de intensidade do ponto de semente, outra técnica foi desenvolvida, conhecida como tolerância multiplicativa, ou do inglês, *multiplicative tolerance*, que utiliza a diferença relativa baseada no nível de tolerância multiplicativa T , que é aplicado conforme a Equação (5.3), determinando assim, a máxima variação de níveis de cinza da região [9, 52].

$$\frac{|f(m,n) - \mu_{Rc}|}{\mu_{Rc}} \leq T \quad (5.3)$$

Capítulo 6 METODOLOGIA

Este capítulo trata da metodologia utilizada durante a execução do trabalho, onde é explicado como são realizadas as etapas de pré-processamento, segmentação com o algoritmo de crescimento de região, formas de lançamento de semente automática, cálculo do volume do fígado e os cálculos estatísticos para a análise dos resultados.

6.1 Equipamento Utilizado

Todas as imagens utilizadas foram adquiridas do mesmo equipamento de TC, modelo Aquilion 64 TSX-101A fabricado pela empresa Toshiba Corporation [58].

Este equipamento pode ser utilizado para adquirir imagens de qualquer parte do corpo em vários eixos (transaxial). O tubo de raios-X possui capacidade de 7,5 *Million Heat Unit* (MHU) e a potência de saída é da ordem de 60 quilowatts (kW). A corrente do tubo de raios-X varia de 10 a 500 miliamperes (mA) utilizando uma tensão de trabalho que pode chegar a 135 quilovolts (kV) [58].

Esse modelo possui 64 canais, e o detector presente é do tipo multicorte (do inglês *Multislice*), permitindo cortes com espessura mínima de 0,5 milímetro e espessura máxima de 10 milímetros, podendo chegar a 16 bits de resolução de contraste [58].

6.2 Aquisição das imagens

A primeira etapa foi a seleção dos exames de TC da região abdominal que contemplassem toda a região do fígado e que tivessem sido realizados com a aplicação de contraste radiológico, no setor de radiologia do Hospital de Clínicas da Universidade Federal da Uberlândia (HC). Esta seleção foi feita junto ao especialista e foi elaborada uma tabela com os números de prontuários correspondentes a estes exames.

Em cada exame foi marcada a primeira e a última fatia que faziam parte da região hepática. Por esse processo foram salvas 5008 fatias (imagens) da fase arterial que continham partes do fígado, o que corresponde a exames de TC da região abdominal de 31 pacientes diferentes.

Por motivo de sigilo médico-paciente, as imagens foram renomeadas com um código sequencial, para que os números de prontuários ou quaisquer outras informações que possibilitem a quebra desse sigilo não fossem divulgados, e desta forma foram utilizadas somente as imagens e as informações contidas no cabeçalho da imagem, extraídas do padrão DICOM [43], necessárias para a correta abertura e manipulação da imagem de TC.

Após coletar as imagens e selecionar as fatias que continham partes do fígado, em cada um dos exames, foi feita a segmentação manual do fígado em cada fatia para todos os exames.

As mesmas imagens selecionadas também foram utilizadas no processo de segmentação automática. Neste processo foi feito pré-processamento das imagens e a segmentação por crescimento de região.

6.3 Segmentação Manual do Fígado

A segmentação manual do fígado foi realizada para que se tivesse outra forma de segmentação hepática, permitindo assim a realização de comparação com a segmentação automática, proposta neste trabalho.

O software *ImageJ* [59] foi utilizado por alunos de iniciação científica para que pudesse ser feita a segmentação manual. Esses alunos foram treinados e supervisionados durante o processo, de forma a ser obtida a segmentação mais fidedigna possível do fígado.

A separação das fatias entre os alunos respeitaram a divisão dos exames, ou seja, independente da quantidade de fatias que contém o fígado no exame, o mesmo foi segmentado apenas por uma pessoa. Após a segmentação manual, um especialista validou todas as imagens segmentadas pelos alunos de iniciação científica.

Para tal, foi padronizada uma metodologia para o processo de segmentação manual, a fim de minimizar o erro durante o procedimento, seguindo os passos presentes no algoritmo, Quadro 6.1.


Quadro 6.1 – Algoritmo de segmentação manual.

<p>Verificação dos limites do fígado</p> <ul style="list-style-type: none"> • Verificar qual o número da primeira e última fatia (limites) que contém alguma porção do fígado no exame analisado na tabela previamente construída para esta finalidade;
<p>Abertura da Imagem</p> <ul style="list-style-type: none"> • Abrir o software ImageJ; • Se for a primeira fatia do exame: Carregar o arquivo DICOM que corresponde a primeira fatia que contém o fígado (Considerando passo acima); • Caso não seja a primeira : Carregar o arquivo DICOM que corresponde a fatia em sequência , até chegar na última fatia com fígado (baseado no passo anterior);
<p>Pré-Processamento</p> <ul style="list-style-type: none"> • Alterar o tipo do arquivo que foi carregado para tipo RGB (<i>Menu Suspense "Image -> Type -> RGB Color"</i>)
<p>Seleção do fígado</p> <ul style="list-style-type: none"> • Na barra de ferramentas, selecionar a ferramenta (Clicar com o botão direito do mouse) para seleção de área a mão livre "<i>Freehand Selections</i>"; • Com o cursor do mouse selecionar a região hepática na fatia;
<p>Processamento da Seleção</p> <ul style="list-style-type: none"> • Utilizar o comando <i>Drawn</i> (<i>Menu Suspense "Edit -> Drawn" ou "CTRL+D"</i>) para fixar a seleção da imagem; • Utilizar o comando <i>Measure</i> (<i>Menu Suspense "Analyze -> Measure" ou "CTRL+M"</i>) para retornar a medida de área selecionada;
<p>Armazenamento dos Dados</p> <ul style="list-style-type: none"> • Salvar a janela com a área em formato de texto (*.txt), com o nome do arquivo no padrão: "<i>NomeDaImagemOriginal-Medida.txt</i>"; • Salvar a imagem onde foi realizado a marcação de área em formato "JPG" ou "JPEG", com o nome do arquivo no padrão: "<i>NomeDaImagemOriginal-Selecao.jpg</i>";

Na Figura 6.1, foram inseridos alguns exemplos da forma que foi realizada a segmentação manual, onde a interface do software *ImageJ* pode ser observada na Figura 6.1(a), a seleção da região do fígado na Figura 6.1(b) e o valor da área do fígado selecionado na Figura 6.1(c).

Figura 6.1 – (a) Menus do software *ImageJ* com a ferramenta de *freehand selection* selecionada, (b) fatia de TC com a área selecionada utilizando o software *ImageJ*, (c) Valor da mensuração da área da fatia que estava selecionada anteriormente, o valor é medido em milímetros.

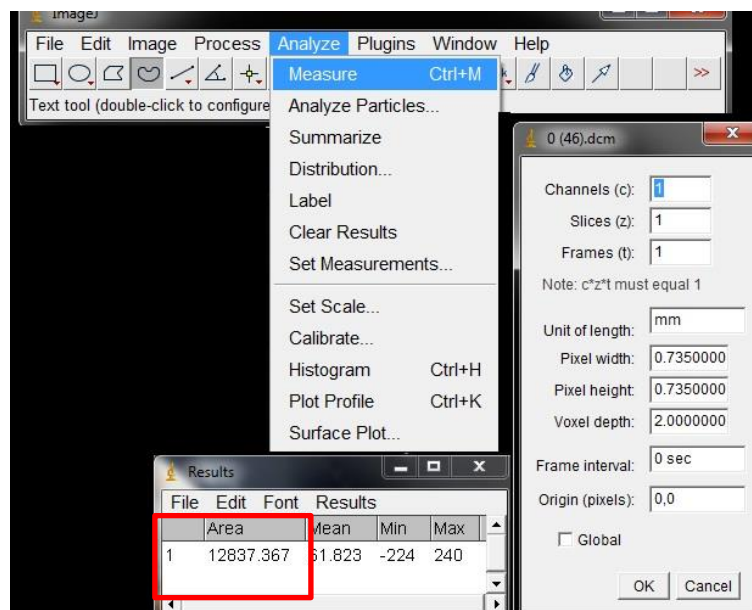
(a)



(b)



(c)



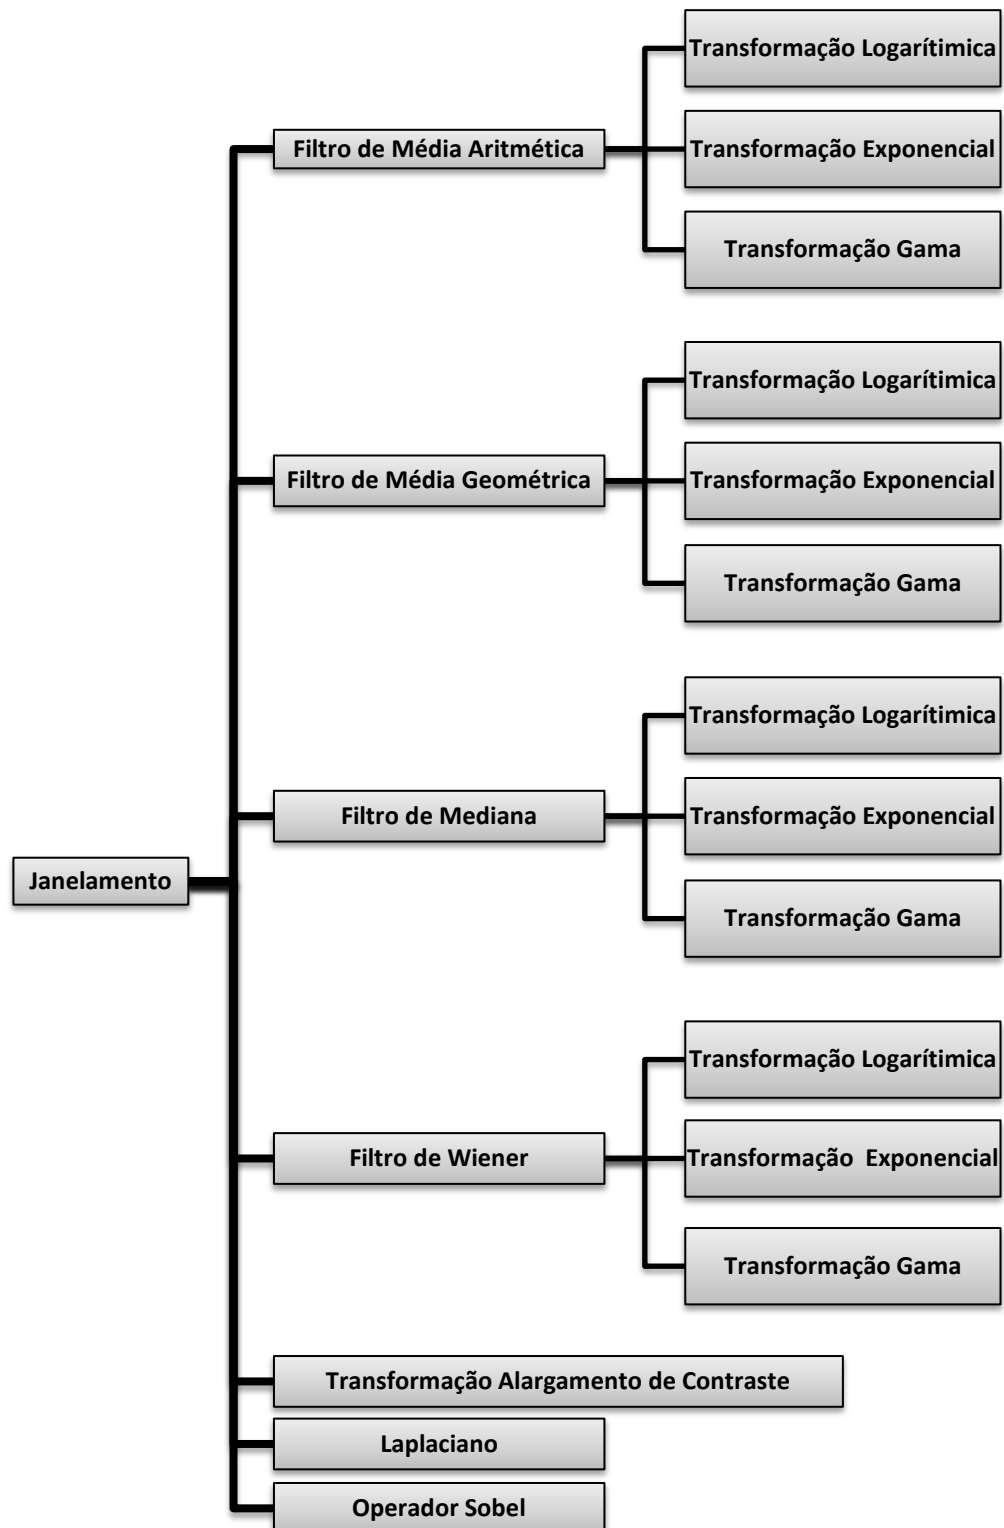
6.4 Pré-processamento

As fatias de TC da região abdominal utilizadas estão salvas em 16 bits, porém, desses, apenas 12 bits são realmente utilizados para armazenar as informações úteis da imagem, possibilitando 4096 variações da escala de níveis de cinza.

Nas fatias, a primeira etapa de pré-processamento é a aplicação do janelamento para que melhor sejam visualizadas as estruturas presentes nas fatias. Em sequência é realizado o processamento da fatia utilizando uma combinação de filtros com a finalidade de reduzir o ruído presente na fatia e realçar as bordas do fígado, para que então seja alcançado um melhor resultado no processo de segmentação, uma vez que, a técnica de segmentação utilizada é sensível a variações de intensidade de níveis de cinza na região da imagem que se deseja segmentar.

Dessa forma, neste trabalho, foram testadas algumas combinações de técnicas de realce de contraste e redução de ruído para avaliar qual a mais eficiente para alcançar a melhor segmentação hepática. As técnicas utilizadas são apresentadas no fluxograma da Figura 6.2 e são detalhadas nas seções seguintes.

Figura 6.2 – Diagrama com as combinações de técnicas utilizadas no pré-processamento das fatias.



6.4.1 Janelamento

O olho humano possui uma limitação referente à quantidade de tons de cinza que consegue diferenciar, algo entre 20 a 30 tons de cinza numa imagem [50]. Dessa forma para melhorar a visualização pelo olho humano das estruturas de interesse no exame de TC, antes de iniciar o exame, o técnico de radiologia seleciona qual a região do corpo que será realizado o exame, baseado na solicitação do médico radiologista (por exemplo, se o exame é para ver estruturas ósseas, abdômen, cérebro, pulmão, fígado, dentre outros).

Assim, no software do tomógrafo é definida uma função de transformação de contraste, o efeito é semelhante a realizar uma alteração da curva característica de absorção do sensor dos raios-X [60], com o objetivo de proporcionar uma melhor visualização do tipo de estrutura escolhida. Este processo é conhecido pelo nome de Janelamento ou do termo em inglês *Windowing*. A informação dos parâmetros da transformação é salva em duas *tags* DICOM da fatia, de número (0028,1050) e (0028,1051), para que durante a visualização da fatia sejam limitados os tons de cinza que serão observados.

Então, considerando as informações presentes nas *tags* DICOM de número (0028,1050) e (0028,1051), que são referentes aos valores de Centro da Janela (do inglês *Window Center* – *WC*) e do Tamanho da Janela (do inglês *Window Width* – *WW*) respectivamente, é feito o janelamento através da Equação (6.1).

$$PxSaída = \begin{cases} \left(\frac{WW}{2}\right) - WC, & \text{se } PxEntrada \leq ((WW/2) - WC) \\ \left(\frac{WW}{2}\right) + WC, & \text{se } PxEntrada \geq ((WW/2) + WC) \\ PxEntrada, & \text{caso contrário} \end{cases} \quad (6.1)$$

Onde:

- *PxSaída* é o valor do pixel de saída da fatia;
- *PxEntrada* é o valor do pixel de entrada da fatia;
- *WC* é o valor do Centro da Janela da fatia;
- *WW* é o valor do Tamanho da Janela da fatia.

Na Figura 6.3(a) é apresentada a imagem original de entrada e na Figura 6.3(b) seu histograma, enquanto na Figura 6.4(a) é apresentada a mesma imagem após a aplicação do janelamento e na Figura 6.4(b) o seu respectivo histograma.

Figura 6.3 – (a) Fatia de TC do abdômen sem qualquer processamento de intensidade de nível de cinza, (b) histograma da fatia sem processamento.

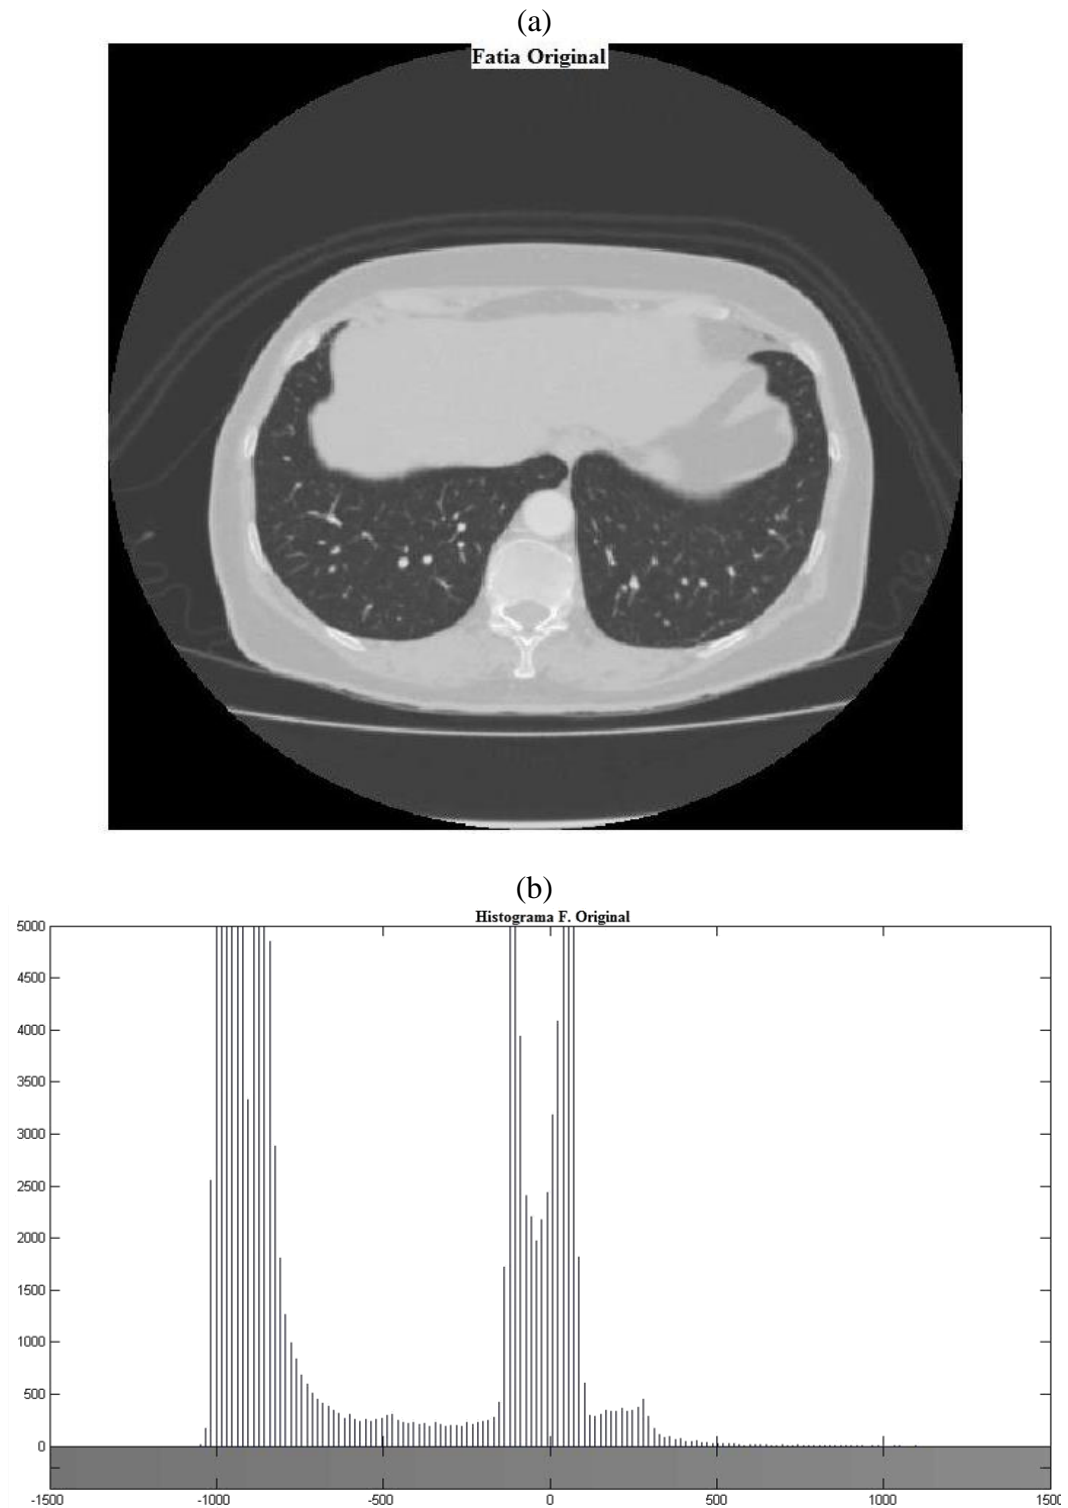
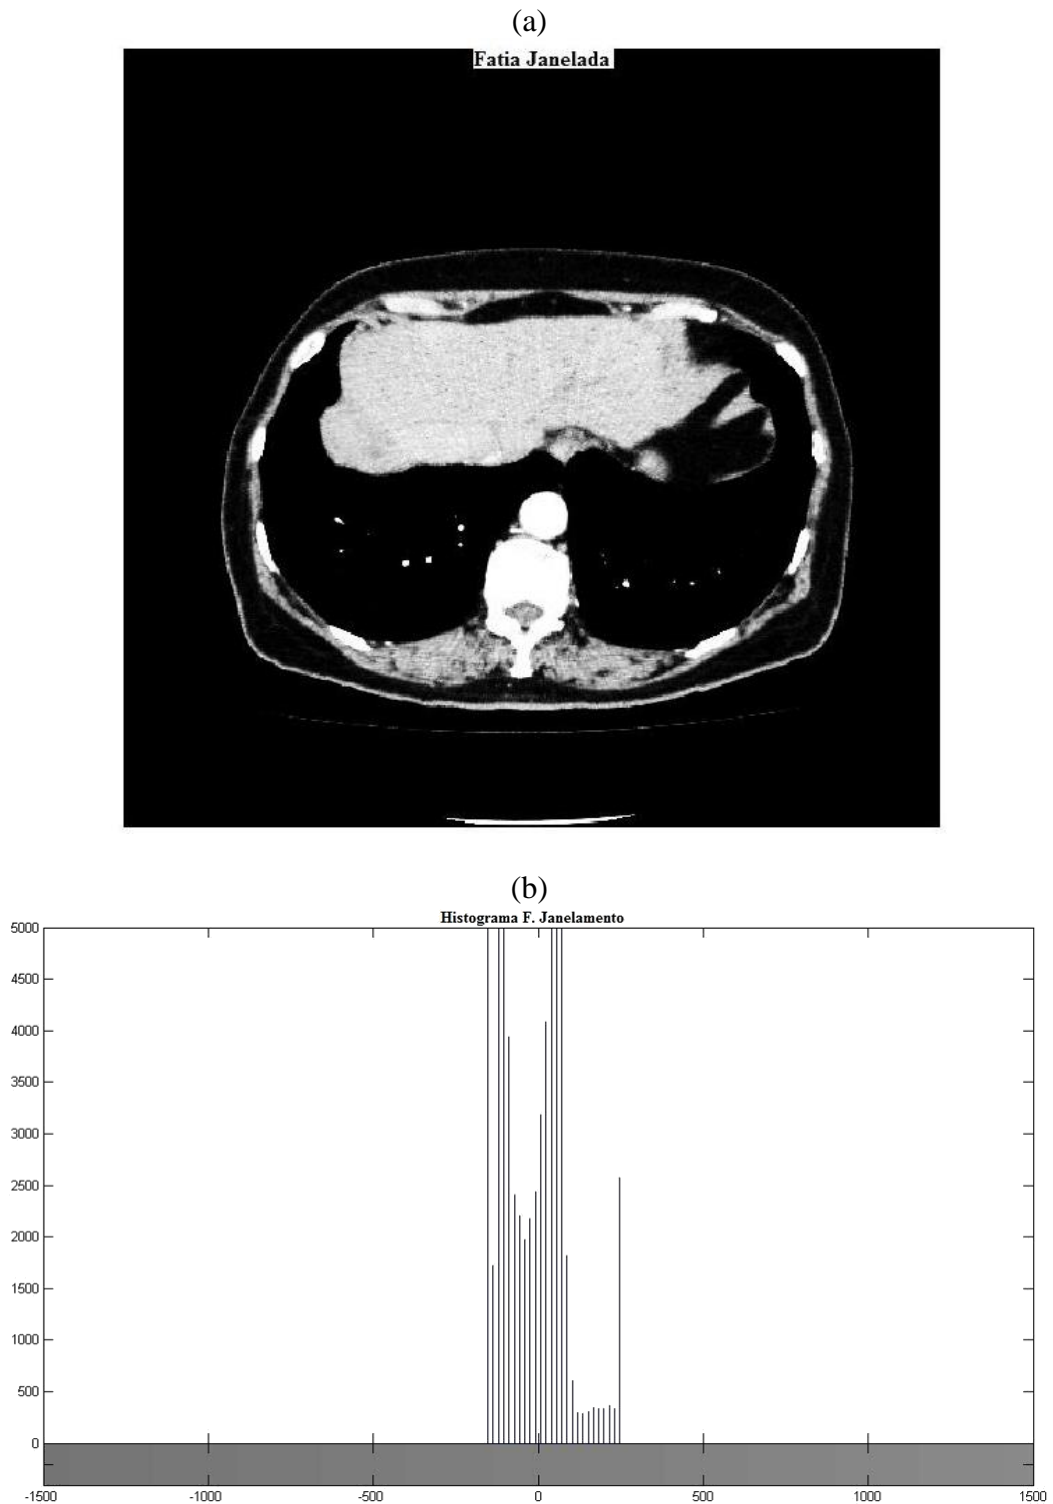


Figura 6.4 – (a) Fatia de TC do abdômen após a aplicação do Janelamento, (b) histograma da fatia com o Janelamento.




No caso do janelamento presente nessas fatias para região abdominal, o tamanho da janela é de 400 níveis de cinza, sendo centralizado na intensidade 40, ou seja, os níveis de cinza (considerando a escala de HU) presentes na fatia após o processamento variam de -160 a 240.

Após o janelamento das imagens com a Equação (6.1) foi aplicado filtro de média aritmética, filtro de média geométrica, filtro de mediana e filtro de Wiener combinados com a transformação logarítmica, transformação exponencial, transformação gama e também individualmente, a transformação de alargamento de contraste, o operador Laplaciano e o Operador Sobel.

6.4.2 Filtro de Média Aritmética

O filtro de média aritmética é aplicado nas fatias para ser observado seu comportamento quando é realizada a alteração de tamanho da máscara. Os resultados desta variação podem ser observados na Figura 6.5. Na Figura 6.5(a) pode ser observada a imagem sem a aplicação do filtro de média aritmética. Já quando é aplicado o filtro de média aritmética com tamanho de vizinhança [3X3] (Figura 6.5(b)) acontece a remoção ruídos de forma suave preservando os detalhes da imagem, ao contrário do que acontece com as imagens quando é aplicado o mesmo filtro aumentando o tamanho da máscara para [9X9] e depois para [27X27], onde não mais é possível visualizar os detalhes da imagem (Figura 6.5(c) e (d)).

Figura 6.5 – Aplicação de vários tamanhos da máscara do filtro de média aritmética, em (a) É a fatia somente com o janelamento, o filtro de média aritmética foi aplicado alterando somente o tamanho da máscara: (b) tamanho de vizinhança [3X3], (c) tamanho de vizinhança [9X9] e (d) tamanho de vizinhança [27X27].




Assim, para remover os ruídos aleatórios com a preservação dos detalhes das fatias de TC será aplicado o filtro de média aritmética de tamanho de vizinhança [3X3].

6.4.3 Filtro de Média Geométrica

Para que seja visualizada a forma de atuação do filtro de média geométrica nas fatias de TC, é realizada a aplicação deste filtro nas fatias de TC variando o tamanho da máscara, conforme é observado na Figura 6.6. Na Figura 6.6(a) é visualizado a fatia sem a aplicação deste tipo de filtro numa fatia de TC da região abdominal, em sequência foi aplicado os filtros de tamanhos de vizinhança [3X3], [9X9] e [27X27] conforme Figura 6.6(b), (c) e (d) respectivamente, sendo observado que ocorreu uma degradação acentuada na imagem quando a máscara do filtro de média geométrica tem seu tamanho incrementado.

Figura 6.6 - Aplicação de vários tamanhos da máscara do filtro de média geométrica, em (a) é observado à fatia de TC com o janelamento, (b) utilizado uma máscara de tamanho de vizinhança [3X3], (c) a máscara tem o tamanho aumentado para [9X9] e em (d) a máscara utilizada é de tamanho [27X27].




O filtro de media geométrica utilizado nos processamentos das fatias será de tamanho de vizinhança [3X3], que conseguiu remover ruídos sem degradar a imagem, tornando possível a identificação das estruturas presentes nas fatias.

6.4.4 Filtro de Mediana

A resposta desse tipo de filtro, quando variado o tamanho da máscara, pode ser observada na Figura 6.7, sendo que na primeira imagem (Figura 6.7(a)) está a fatia sem o processamento pelo filtro de mediana. Na Figura 6.7(b) pode ser observado a fatia processada com filtro de mediana de tamanho de vizinhança [3X3], já na Figura 6.7(c) a mesma fatia processada com filtro de tamanho de vizinhança [9X9] e por fim na Figura 6.7(d) é observado o processamento da fatia pelo filtro de tamanho de vizinhança [27X27].

Figura 6.7 – Em (a) é observado à fatia da região abdominal sem a aplicação do filtro de mediana (somente com janelamento), em (b) foi aplicado o filtro de mediana com a máscara de tamanho de [3X3], em (c) o filtro de mediana possui máscara de tamanho [9X9] e por fim em (d) o filtro de mediana aplicado tem a máscara de tamanho [27X27].




A máscara de mediana utilizada durante o processamento das fatias será de tamanho de vizinhança [3X3], uma vez que a máscara deste tamanho não causou muita degradação nas fatias.

6.4.5 Filtro de Wiener

O comportamento do filtro de Wiener para as fatias de TC é verificado através da variação do tamanho da máscara, e um exemplo de como este filtro se comporta pode ser observado na Figura 6.8. Na Figura 6.8(a) está a fatia sem processamento pelo filtro (apenas com o janelamento), na Figura 6.8(b) foi aplicado a máscara de tamanho [3X3], na Figura 6.8(c) a máscara tem o tamanho [9X9] e por fim na Figura 6.8(d) a máscara aplicada tinha o tamanho [27X27].

Figura 6.8 – (a) Fatia de TC da região abdominal com a aplicação de janelamento. A aplicação do filtro de Wiener é realizada com os seguintes tamanhos de máscara: (b) [3X3], (c) [9X9] e (d) [27X27].



O tamanho do filtro de Wiener utilizado no processamento das fatias será de tamanho [3X3], por não degradar muito as estruturas das fatias.

6.4.6 Transformação Logarítmica


Esta transformação é aplicada na fatia conforme a forma geral apresentado na Equação (6.2, em sequência, onde o $PxOut$ corresponde ao valor do pixel de saída, c corresponde a uma constante e o $PxIn$ ao valor do pixel de entrada.

$$PxOut = c * \log(1 + PxIn) \quad (6.2)$$

O resultado da aplicação da transformação logarítmica numa fatia de TC que contém parte do fígado é apresentado na Figura 6.9(a). Pode ser observado na Figura 6.9(b) que ocorreu à expansão da faixa de níveis de cinza da fatia, quando utilizado o valor de constante igual a $c=0,0001$, porém quando utilizado o valor da constante $c=20$ (Figura 6.9(c)), ou seja,

maior que 1, aconteceu a expansão dos pixels mais escuros e uma compressão dos pixels com valor de intensidade mais alta e por fim na Figura 6.9(d) pode ser observado a intensificação do resultado presente na figura anterior quando é aplicado o valor de $c=100$.

Figura 6.9 – (a) Fatia TC janelada da região hepática; Resultado do calculo da transformação logarítmica utilizando c igual à: (b) $c=0,0001$, (c) $c=20$ e (d) $c=100$.



6.4.7 Transformação Exponencial


A transformação exponencial é aplicada na fatia de TC, utilizando o formato da Equação (6.3) (numa imagem com os níveis de cinza normalizado), onde $PxOut$ é o valor do pixel de saída, $PxIn$ é o valor do pixel de entrada e C é o valor que corresponde uma constante de deslocamento.

$$PxOut = e^{\left(\frac{PxIn}{C}\right)} - 1 \quad (6.3)$$

Utilizando esta equação, variando o valor de C , foram obtidos os resultados apresentados na Figura 6.10, sendo que, na Figura 6.10(a) está a imagem original de uma fatia

com uma porção do fígado. Neste processamento foram usados os valores de C igual a $C=30$ (Figura 6.10(b)), $C=60$ (Figura 6.10(c)) e $C=120$ (Figura 6.10(d)) e, com isso, foi observado que quanto menor o valor da constante, menores as variações de contraste visualizadas.

Figura 6.10 – (a) Fatia de TC janelada. Resultado do calculo da transformação exponencial com: (b) $C=30$, (c) $C=60$ e (d) $C=120$.



6.4.8 Transformação de Potência


A transformação de potência (transformação gama) é calculada sobre a fatia de TC utilizando a Equação (6.4, onde $PxOut$ representa o pixel de saída após a aplicação da transformação gama, $PxIn$ é o pixel de entrada a ser processado, C é uma constante e γ é o fator de correção gama.

$$PxOut = C * PxIn^\gamma \quad (6.4)$$

Para exemplificar o funcionamento desta técnica é variado o γ para realizar a transformação de intensidade numa fatia de TC contendo parte do fígado. Na Figura 6.11(a) é

observado a fatia somente com janelamento, na Figura 6.11(b) é aplicado o valor de $\gamma=0,1$ para o fator de correção gama, já na Figura 6.11(c) foi modificado o fator de correção gama para $\gamma=0,5$ e, por fim, na Figura 6.11(d) o fator de correção gama aplicado foi de $\gamma=1,5$.

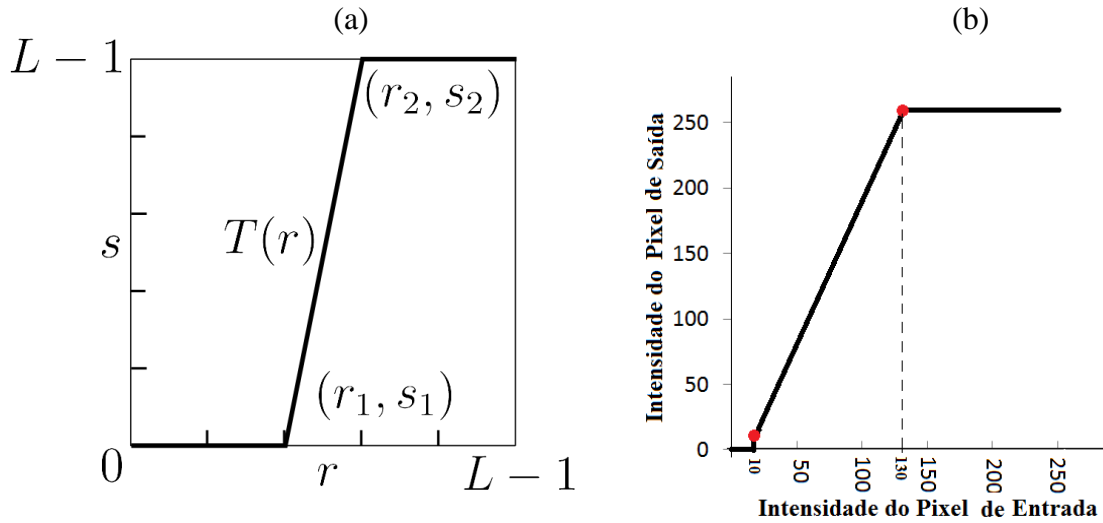
Figura 6.11 – (a) Fatia de TC janelada. É calculada a transformação de potência com: (b) $\gamma=0,1$, (c) $\gamma=0,5$ e (d) $\gamma=1,5$.



6.4.9 Transformação Alargamento de Contraste

A transformação de alargamento de contraste é representada pelo gráfico da Figura 6.12(a). Na Figura 6.12(b) os valores foram substituídos conforme foram utilizados no algoritmo para o processamento das fatias de TC.

Figura 6.12 – (a) Forma geral do Alargamento de Contraste [9], (b) Forma utilizada para realizar a transformação de contraste, com os valores definidos empiricamente.



Onde:

- L é o valor máximo da escala de nível de cinza;
- $T(r)$ é a função de transformação aplicada;
- (r_1, s_1) e (r_2, s_2) controlam o formato da função de transformação.

Este tipo de processamento foi aplicado nas fatias de TC hepáticas para tentar alcançar uma melhor distribuição dos níveis de cinza da faixa de interesse. O algoritmo utilizado para tal processamento pode ser observado no Quadro 6.2.

Quadro 6.2 – Algoritmo do Alargamento de Contraste.

- Copiar a fatia que foi processada com o janelamento numa nova matriz (*imAC*) de mesmo tamanho;
- Fazer busca pixel a pixel na *imAC* procurando por pixels que estejam abaixo do valor 10 de intensidade e para estes definir valor igual a zero;
- Fazer busca pixel a pixel na *imAC* procurando por pixels que estejam acima do valor 130 de intensidade e para estes definir valor igual a 255;
- Fazer busca pixel a pixel na *imAC* procurando por pixels que estejam entre o intervalo de intensidade 10 a 130, e aplicar a seguinte equação:


$$PxOut = (PxIn - 10) * (255 / (130 - 10))$$

Onde: $PxOut$ é o valor do pixel de saída.

$PxIn$ é o valor do pixel de entrada.

Com a aplicação dos passos acima foi gerado um exemplo quando aplicado em uma fatia de TC contendo parte do fígado (Figura 6.13(a)) e esse resultado pode ser observado na Figura 6.13(b).

Figura 6.13 – (a) Fatia TC janelada, em (b) Fatia após processamento pela transformação de alargamento de contraste.



6.4.10 Operador Laplaciano


O operador Laplaciano é aplicado nas fatias de TC conforme o algoritmo que foi utilizado durante a aplicação do filtro laplaciano de centro -8, que pode ser observado no Quadro 6.3.

Quadro 6.3 – Algoritmo usado para a aplicação do operador Laplaciano.

- Varredura da Máscara do operador Laplaciano com centro negativo através da fatia, e armazenamento da matriz resultante numa outra variável (*imLA*);
- Realização de uma subtração entre a fatia janelada e a variável *imLA*, obtendo assim o resultado do processamento por Laplaciano.

O resultado da aplicação do operador Laplaciano é a imagem com as bordas aguçadas, conforme pode ser observado na Figura 6.14, onde na Figura 6.14(a) é observado à imagem original (somente com a aplicação do janelamento) e na Figura 6.14(b) se tem a imagem processada pelo algoritmo de aguçamento de bordas com o operador Laplaciano.

Figura 6.14 – (a) Fatia Janelada; (b) Fatia após o processamento pelo operador Laplaciano.



6.4.11 Operadores de Sobel


O operador de Sobel foi aplicado nas fatias que já haviam sido submetidas ao processo de janelamento. A forma de como foi realizado o processamento pode ser observado no Quadro 6.4.

Quadro 6.4 – Algoritmo do Processamento pelos Operadores de Sobel.

- Criação das matrizes *imS1*, *imS2* e *imSobel* com valores iguais a zero possuindo mesmo tamanho da fatia que será processada por esta técnica;
- Varredura da Máscara Vertical através da fatia, e armazenamento da nova matriz numa variável (*imS1*);
- Varredura da Máscara Horizontal através da fatia, e armazenada a nova matriz numa outra variável (*imS2*);
- Realização do processo de soma das duas matrizes *imS1* e *imS2*. O resultado desta soma é armazenado na variável *imSobel*;
- Adição da fatia janelada com a variável *imSobel*, obtendo assim o resultado do processamento pelos Operadores de Sobel.

Como resultado do processamento, por esse tipo de filtro espacial, é obtida uma imagem com as bordas realçadas vertical e horizontalmente. Um exemplo deste filtro pode ser observado na Figura 6.15 em sequência, na Figura 6.15(a) está a fatia com o janelamento e na Figura 6.15(b) tem-se a mesma fatia após o processamento pelos Operadores de Sobel.

Figura 6.15 - (a) Fatia janelada, (b) Fatia após o processamento pelos Operadores de Sobel.



6.4.12 Combinação dos Efeitos das Técnicas

As combinações de algumas das técnicas, citadas nas seções anteriores, foram realizadas para verificar qual contribuiria mais para que fosse alcançado o melhor resultado na segmentação do fígado, quando utilizado o algoritmo de crescimento de região.

As combinações foram testadas, conforme apresentado na Figura 6.2, a fim de obter a redução de ruído associado com a melhora no realce de contraste. Os resultados destas combinações serão apresentados na seção 7.5.2.

6.5 Segmentação utilizando algoritmo de Crescimento de Região

Para realizar a segmentação foi utilizada a técnica de crescimento de região (conforme descrita no Capítulo 5). Esta técnica realiza o agrupamento de pixels semelhantes (com conectividade-8) formando regiões, considerando uma pequena variação na intensidade dos pixels, de ± 15 níveis de cinza, valor escolhido por representar 75% da variação de níveis de cinza para o fígado na escala de Hounsfield [61], durante o processo de agrupamento.


Esta técnica inicia o seu crescimento a partir de um ponto definido previamente (ponto de semente), onde o valor de intensidade de nível de cinza deste ponto é comparado com os valores de intensidade de níveis de cinza dos pixels de sua vizinhança na imagem de entrada, e caso sejam semelhantes suas coordenadas são incorporadas à região segmentada. A região vai sofrendo um incremento de área (em forma circular), fazendo a comparação da intensidade de níveis de cinza dos novos pontos adicionados à região com o nível de cinza do

ponto de semente, e caso sejam semelhantes suas coordenadas são adicionadas na região de segmentação.

O processo de incremento de área da região circular e da comparação de semelhança com o ponto de semente acontece até quando não sejam mais detectados pixels semelhantes ao ponto de semente.

O resultado do processo de segmentação é uma imagem binária, onde os pixels com valores iguais a 1 representam a segmentação, que neste caso é a segmentação do fígado. Um exemplo da imagem segmentada utilizando esta técnica é apresentado na Figura 6.16(a) e a mesma imagem sobreposta com a imagem da fatia em Figura 6.16(b).

Figura 6.16 – (a) Fígado segmentado; (b) Sobreposição do fígado segmentado na fatia original.



6.6 Lançamento da Semente


O lançamento da semente, ponto inicial onde começa o agrupamento de pixels na segmentação pelo algoritmo de crescimento de região, foi realizado de forma automática por três algoritmos diferentes que foram desenvolvidos para essa finalidade.

6.6.1 Região Interna das Costelas

Antes de iniciar com os algoritmos para realizar o lançamento de semente de forma automática, primeiramente foi necessário encontrar as coordenadas das costelas. Na primeira parte deste algoritmo é realizada uma cópia da imagem em uma nova variável (*imOsso*) e na *imOsso* é realizado um processo de limiarização, ou seja, uma modificação nos valores de

intensidade dos pixels da imagem, sendo definido como a intensidade de nível de cinza zero os pixels que possuam valor menor que o esperado para tecido ósseo (considerando a escala de Hounsfield [61]). O valor do nível de cinza que corresponde a essa intensidade é de 230 em 8 bits de resolução). Na Figura 6.17 pode ser observada uma fatia após o processamento por este método.


Figura 6.17 – Fatia limiarizada mostrando somente os ossos.



Em seguida foram procurados na imagem resultante do processo de limiarização os limites dos ossos (costelas) em quatro direções (Vertical, da borda esquerda para o centro – VbE ; Vertical, da borda direita para o centro – VbD ; Horizontal, da borda superior para o centro – HbS ; Horizontal, da borda inferior para o centro – HbI).

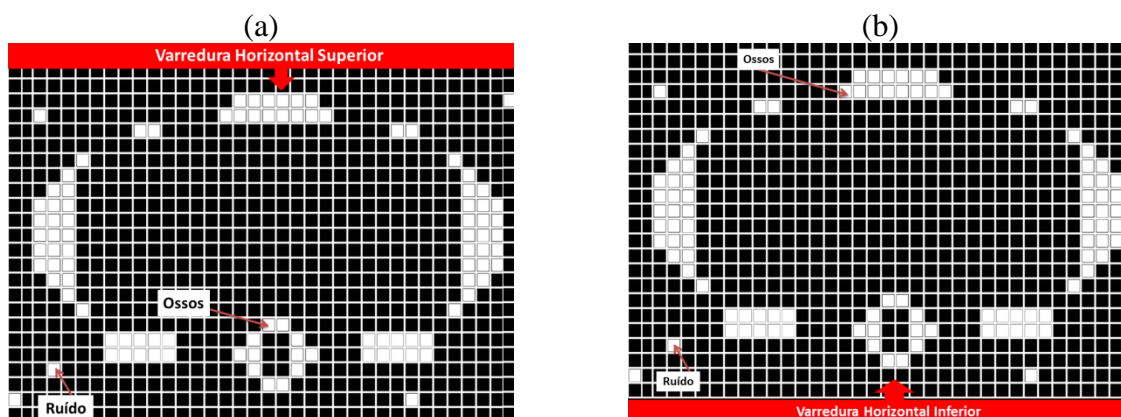
Na procura da costela na VbE (Figura 6.18(a)) são somados os valores de intensidade de pixel, coluna a coluna, iniciando do ponto de coordenadas $x=0$ e $y=0$ ($imOsso(0,0)$), até que a soma seja maior que o valor 10 (definido empiricamente), e então é armazenada a coordenada do ponto de parada da varredura, seguindo a condição de soma >10 , definindo assim a coordenada VbE . De forma semelhante é realizado para encontrar a coordenada VbD (Figura 6.18(b)), porém, é iniciada a varredura a partir da última coluna da imagem (no ponto ($imOsso(0,512)$), ou seja, $x=0$ e $y=512$). Então é realizado um decremento da coordenada da coluna e é feita a soma dos valores de intensidade de pixel coluna a coluna, até ser encontrado o resultado que seja superior a 10, que de forma semelhante a definição de VbE , é definida VbD .

Figura 6.18 – (a) Representação da forma de varredura da matriz da imagem para VbE , e em (b) para VbD .




Para o HbS (Figura 6.19(a)) e HbI (Figura 6.19(b)) procede-se de forma semelhante aos dois anteriores, porém é realizado uma variação do valor da coordenada da linha até que sejam encontrados valores que satisfaçam a condição (soma de valores de intensidade de pixel >10), e então são armazenados os valores dessas duas variáveis.

Figura 6.19 – (a) Representação da forma de varredura da matriz da imagem para HbS , e em (b) HbI .



Assim que definido os valores das coordenadas da região interna das costelas é realizada uma combinação desses valores obtidos para as quatro direções, para que, então, sejam obtidas as coordenadas de cada vértice da região. Na Figura 6.20 é apresentado um exemplo deste processo.

Figura 6.20 – Representação da localização dos pontos (VbE , VbD , HbS , HbI) na matriz da fatia de TC.




Pelo conhecimento da anatomia humana é sabido que a maior parcela do fígado está localizada na porção esquerda de uma fatia tomográfica axial. Assim, com o intuito de poupar recursos computacionais e também diminuir a probabilidade de erro no lançamento da semente, já que existem órgãos do lado direito da fatia com tons de cinza muito próximo ao esperado para o fígado, é considerada apenas a metade esquerda da fatia para realizar os processamentos.

6.6.2 Área de lançamento de semente em região retangular


Considerando a região delimitada pelos pontos, conforme exemplificado na Figura 6.20, é definida uma máscara binária de mesmo tamanho da fatia de TC, sendo esta preenchida com pixel de valor 1 na região delimitada pelos vértices e com pixels de valor igual a 0 no resto da imagem, conforme Figura 6.21. Assim em cada fatia a região retangular possui tamanho e localização diferentes.

Figura 6.21 – Representação da máscara da região.



Uma multiplicação é realizada, pixel a pixel, da máscara binária pela fatia pré-processada que contém parte do fígado, que se deseja encontrar o ponto de semente para realizar a segmentação. O resultado deste processo é uma imagem onde, apenas uma porção do fígado (em forma retangular) é preservada, conforme Figura 6.22(a) e (b).

Figura 6.22 – (a) Fatia original na primeira coluna. (b) Recorte com a porção do fígado em forma retangular da mesma fatia.



Nesta imagem resultante da multiplicação pela máscara binária (Figura 6.22(b)), que contém apenas uma porção do fígado, ocorre a busca por toda a imagem, utilizando uma máscara de tamanho de vizinhança [7X7], por regiões que contenham todos os pixels similares ao valor esperado para fígado com contraste radiológico (variando de 110 a 130 as

intensidades dos pixels [48]), sendo armazenada na variável de pontos (P_f) a média dos pontos (\widetilde{X}_2) desta região, quando satisfeita a condição de pixels com valor de intensidade no intervalo de 110 a 130.

Após a busca por toda a região é calculada a média dos pontos que foram armazenados na variável de pontos (P_f), obtendo, assim, um ponto que representa o centro de massa dos pontos, que neste caso é considerado como sendo o ponto de semente definido através da Área de Lançamento de Semente em Região Retangular (ALSRR), a ser utilizado no algoritmo de crescimento de região para a segmentação hepática. A equação que representa todo esse processo pode ser observada na Equação (6.5).

$$\begin{aligned} \widetilde{X}_2(i, j) &= \sum_{i=HbS}^{HbI} \sum_{j=VbE}^{VbD} \sum_{k=-3}^3 \sum_{l=-3}^3 \frac{f(k-i, l-j)}{49} \\ P_f(i, j) &= \left[\left[\left[\sum_{i=0}^{TamanhoPontos\ em\ i} \frac{\widetilde{X}_2(i, 1)}{TamanhoPontos\ em\ i} \right] \right] \right. \\ &\quad \left. \left[\left[\sum_{j=0}^{TamanhoPontos\ em\ j} \frac{\widetilde{X}_2(j, 2)}{TamanhoPontos\ em\ j} \right] \right] \right] \end{aligned} \quad (6.5)$$


6.6.3 Área de lançamento de semente em região elíptica

A diferença desta técnica de lançamento de semente em relação a que foi explicada na subseção anterior está no formato da região de lançamento que, neste caso, é uma região elíptica, para que melhor seja selecionada a região hepática de forma a minimizar a seleção de região que contenha partes da costela ou partes do músculo. Esta técnica foi desenvolvida procurando melhorar os resultados que foram obtidos com a técnica anterior na seleção de sementes para realizar a segmentação do fígado.

A elipse é calculada, conforme Equação (6.6), considerando os valores encontrados para limite da região abdominal (VbE , VbD , HbS e HbI). Desta forma, em cada fatia a elipse possui tamanho e localização diferentes. Essa máscara é, por fim, multiplicada por uma cópia da imagem pré-processada, obtendo como resultado uma imagem com uma região elíptica que possui uma porção do fígado, conforme pode ser observada na Figura 6.23. Essa região elíptica é definida como sendo a Área de Lançamento da Semente em Região Elíptica (ALSRE).

$$Ellipse = \sum_{x=0}^{VbD/2} \sum_{y=0}^{Hbl/2} \frac{(x - (\frac{VbD + VbE}{2}))^2}{(\frac{VbD}{2})^2} + \frac{(y - \frac{Hbl + HbS}{2})^2}{(\frac{Hbl}{2})^2} \quad (6.6)$$

Figura 6.23 – Duas fatias com partes diferentes do fígado com suas respectivas ALSRE selecionadas.



Após a definição da ALSRE é realizado a busca por pixels na imagem da região elíptica, que estão no intervalo de 110 a 130 de valores de intensidade de pixel, sendo considerada uma região interna de tamanho [7X7] e este intervalo é o esperado para fígado, quando o exame é realizado com a aplicação de contraste radiológico [48]. Assim como na técnica anterior é armazenada a coordenada central de cada uma das regiões que tiveram a

totalidade dos pixels atendendo a esta condição e, em seguida, é calculada a média destes pontos, conforme foi exemplificado pela Equação (6.5) na seção anterior.


6.6.4 Área de lançamento de semente em região circular

A Área de Lançamento de Semente em Região Circular (ALSRC), assim como a técnica anterior, foi desenvolvida como uma tentativa de aprimorar os resultados obtidos com a ALSRR e verificar se a presença dos ossos e músculos abdominais influencia no processo de lançamento automático de semente.

Para desenvolver esta técnica são utilizadas três dilatações morfológicas em formato circular (morfologia matemática [62]) diferentes. A primeira dilatação circular é realizada para remover os ossos da coluna (que está no centro da fatia) e também os rins (por possuir níveis de cinza próximos aos níveis de cinza do fígado). A segunda dilatação é realizada para a remoção das costelas e a terceira é realizada para remover estruturas centrais que possam aparecer na fatia (partes do estômago ou coração).

Na primeira dilatação circular é definido o ponto inicial nas coordenadas (512,256), formando um semicírculo (*imDI1*). A imagem negativa dessa dilatação é multiplicada pela fatia que passou pelo processo de janelamento, obtendo uma imagem onde foi removida a coluna vertebral e as estruturas inferiores do abdome (*imRI*). Um exemplo de como a imagem fica após essa primeira dilatação pode ser observado na Figura 6.24.


Figura 6.24– Imagem resultante após a multiplicação da *imDI1* pela fatia original.



Para definir a segunda dilatação é criada uma imagem onde estão presentes apenas os ossos na fatia (*imOsso*), assim como descrito na “Região Interna da costela”. Usando a


imOsso (que é uma imagem binária) é realizada a dilatação circular, tendo como seu ponto inicial de crescimento o centro da imagem nas coordenadas (256,256). A dilatação circular ocorre até que seja detectado algum pixel com intensidade diferente de zero, significando que foi encontrada alguma parte óssea, gerando, assim, uma imagem binária com esta dilatação (*imDI2*). Através da multiplicação da *imDI2* com a imagem *imR1*, resultante da primeira dilatação circular (Figura 6.24) é obtida a imagem *imR2*, que é o resultado da remoção de todas as estruturas que estão na região externa aos ossos (inclusive). Um exemplo de uma imagem, após o processamento descrito, é apresentado na Figura 6.25.

Figura 6.25 – Imagem resultante da multiplicação da *imDI2* com a imagem *imR1*.



O próximo passo é iniciar uma dilatação circular (*imDI3*) no ponto de coordenadas (256,1) e então realizar a multiplicação desta dilatação com a *imR2*, para que sejam removidas algumas outras estruturas que possam atrapalhar o lançamento de semente, principalmente na área central da imagem abdominal (Coração e estômago, por exemplo). Nessa etapa é também feito a remoção da metade direita da fatia, garantindo que a área de lançamento de semente será composta apenas por partes do fígado, obtendo assim a ALSRC. Um exemplo desta área de lançamento de semente é observado na Figura 6.26.

Figura 6.26 – Imagem da ALSRC.



Assim como nas sessões anteriores, “Área de lançamento de semente em região retangular” (ALSRR) e “Área de lançamento de semente em região elíptica” (ALSRE), a “Área de Lançamento de Semente em Região Circular” (ALSRC) é definida para que se faça a busca pelo melhor ponto de lançamento da semente. Uma máscara [7X7] é deslocada sobre a região circular buscando por pixels cujos valores de intensidade estejam no intervalo de 110 a 130. Quando toda máscara satisfaz esta condição é armazenado o valor da posição central da máscara. Esta varredura é realizada até que toda a ALSRC seja percorrida. Após isto, é calculada a média dos pontos armazenados definindo o centro de massa dos pontos, e assim é considerado o ponto de semente para ser utilizado no algoritmo de crescimento de região, conforme foi exemplificado pela Equação (6.5).

6.7 Volumetria Hepática

A volumetria hepática é realizada considerando todas as fatias do exame, utilizando cada uma das imagens binária que são obtidas como resultado da segmentação das fatias do exame.

O primeiro passo do algoritmo foi realizar o somatório da quantidade de pixels diferentes de zero nas imagens binárias, resultando no cálculo da área do fígado por fatia. Foi verificado se o resultado desta soma não excede o valor de 120.000 pixels (Valor correspondente a aproximadamente 90% da quantidade de pixels presentes na metade de uma fatia tomográfica de tamanho [512x512]). Caso exceda é atribuído valor de volume igual à zero para esta fatia, caso o valor esteja dentro do limite estabelecido, seu valor é multiplicado pela dimensão do pixel que é medido em milímetros, fornecido pela *tag Pixel Spacing* (0028,0030) da imagem DICOM e, em seguida, essa área é multiplicada pelo *pitch* (Espaço

entre as fatias dado pelo movimento da mesa entre as fatias) – *Spiral Pitch Factor* que é dado pela *tag* (0018,9311) do padrão DICOM. Todo esse processo é resumido através do algoritmo apresentado no Quadro 6.5.

Quadro 6.5 – Algoritmo do cálculo da volumetria hepática.

1° Realizar o Cálculo através da Equação abaixo:

$$VolFe = \sum_{i=0}^{512} \sum_{j=0}^{512} (Sl(i,j) * SPF * PS)$$

* Onde: VolFe é o valor do volume da fatia, Sl representa a imagem segmentada do fígado, SPF é o valor do *Spiral Pitch Factor* e o PS é o valor do *Pixel Spacing*.

2° Se valor de VolFe > 120000, Fazer VolFe=0;

3° Armazenar valor VolFe.

O volume total do fígado é resultante do somatório dos volumes individuais das fatias que compõem o exame de fígado, sendo dado em milímetros cúbicos (mm³), conforme Equação (6.7), onde *VolF* é o volume do exame e *VolFe* representa o volume da fatia.

$$VolF = \sum VolFe \quad (6.7)$$

6.7 Descarte dos volumes excedidos

Para desconsiderar possíveis imagens, onde a região segmentada hepática corresponde a mais de 45% da área total da imagem, caracterizando erro, é atribuído valor de volume igual a zero quando a imagem do fígado segmentado excede o valor de 120.000 pixels não nulos. Esse valor foi escolhido por ser aproximadamente 90% da área correspondente à metade da fatia, ou seja, 512 linhas multiplicadas por 256 colunas, e pela anatomia hepática é improvável que numa única fatia de TC abdominal o fígado ocupe toda essa área.

6.8 Comparação entre Segmentação Automática e Segmentação Manual

A comparação entre os resultados obtidos na segmentação automática e segmentação manual é realizada de duas formas distintas:

- Comparação entre o volume total do exame que foi obtido de forma manual e o volume total do exame que foi obtido de forma automática;
- Comparação do erro fatia a fatia;

6.8.1 Comparação de volume manual e automático

Nesta forma de comparação é utilizado o volume final do exame medido de forma automática e o volume final do exame medido de forma manual, sendo considerado resultado ideal o volume obtido proveniente da segmentação manual.

Essa comparação dos volumes é feita por exame, sendo utilizada a Equação (6.8) para verificar a taxa de acerto do volume automático em percentagem.

$$TaxaAcerto = \left(\left((V_{tM} - V_{tA}) / V_{tM} \right) * 100 \right) - 100 \quad (6.8)$$

Onde:

- V_{tM} : Volume Total do Exame medido manualmente;
- V_{tA} : Volume total do exame medido automaticamente pelo método proposto.

Do resultado desta comparação é obtido um valor em percentagem, podendo ser igual ou menor que 100%. Quando o resultado é menor do que 100% significa que o volume medido pela segmentação automática foi menor ou maior que o medido durante a segmentação manual. Os melhores resultados são os que estão próximos a 100%, significando um resultado semelhante à medida do volume manual.

6.8.2 Comparação do Erro Estatístico

Para realizar esta verificação do erro presente em cada fatia, quando comparada a segmentação manual com a segmentação automática, é utilizada a ferramenta estatística para cálculo de erro conhecida pelo nome de Erro Quadrático Médio (EQM) ou *Mean Squared Error* [63], que é calculado conforme a Equação (6.9).

$$EQM = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2 \quad (6.9)$$

Onde n é a quantidade total de fatias no exame, \hat{Y}_i é o valor do volume da fatia i medido automaticamente e Y_i o valor do volume da fatia i , calculado de forma manual. O resultado deste método é na mesma unidade dos valores inseridos, neste caso em milímetros cúbicos (mm^3). Quanto mais próximo de zero for o EQM, menor a quantidade de erro presente na segmentação automática.

Capítulo 7 RESULTADOS E DISCUSSÃO

Os resultados obtidos pela aplicação dos procedimentos e técnicas de pré-processamento, segmentação automática e cálculo do volume descritas no METODOLOGIA, para as fatias de TC da região abdominal, serão apresentadas neste capítulo.


Dos 31 exames disponíveis e testados neste trabalho, que compreendiam mais de 5000 fatias, os resultados aqui apresentados são referentes a apenas 19 exames, compreendendo 2977 fatias, o que representa uma média de 156 fatias por exame. Isto se deu, pois apenas 19 dos 31 exames foram segmentados manualmente, e então estes foram utilizados como referência para análise e avaliação dos resultados das técnicas de pré-processamento e segmentação, possibilitando o cálculo de taxa de acerto e EQM.

Para melhor compreensão e análise das técnicas desenvolvidas, os resultados são apresentados em ordem cronológica. A quantidade de fatias utilizadas na execução de cada teste foi limitada de acordo com a quantidade de fatias segmentadas manualmente que estavam disponíveis no momento de cada teste realizado.

7.1 Segmentação Manual do Fígado

Na Figura 7.1 pode ser observada a segmentação realizada manualmente da área do fígado de diferentes fases de um mesmo exame de TC.

Figura 7.1 – Seleção manual da região do fígado em diferentes partes do exame (na cor vermelha).



Esta seleção de área, conforme apresentado no METODOLOGIA, foi realizada por alunos de iniciação científica e, então, validada por especialista da área de radiologia.

7.2 Testes preliminares de técnicas de pré-processamento

Para estudar o comportamento do algoritmo de crescimento de região e selecionar os exames que fariam parte deste estudo, primeiramente foram utilizadas aproximadamente 300 fatias de TC, que foram divididas em dois grupos, sendo o primeiro grupo composto por exames realizados utilizando o contraste radiológico (grupo 1) e o segundo grupo composto por exames realizados sem o contraste radiológico (grupo 2).

Todas as imagens foram primeiramente janeladas e então, pré-processadas com as seguintes técnicas para realce de bordas: transformação de alargamento de contraste, filtro de

média aritmética em conjunto com transformação gama, operador Laplaciano e operador Sobel.

Após o pré-processamento das fatias, tanto as pré-processadas com as técnicas previamente citadas quanto as fatias janeladas sem pré-processamento, foram submetidas ao algoritmo de crescimento de região para que fosse realizada a segmentação do fígado. O ponto de semente foi definido de forma manual na região central do fígado em cada fatia.

Para que fosse realizada a avaliação destas técnicas de pré-processamento foram calculados os volumes das fatias apenas com o janelamento, as quais foram utilizadas na segmentação manual, nomeado de Volume Manual – VM. Estas mesmas fatias foram pré-processadas e segmentadas nos moldes citados anteriormente, onde o resultado é o volume para cada uma das técnicas, nomeado de Volume Preliminar – VP. Estes resultados de VM e VP são utilizados para calcular o EQM, sendo, neste caso, considerado como o valor ideal de volume o VM.

Na Tabela 7.1 e na Tabela 7.2 podem ser visualizados os resultados alcançados com cada técnica de pré-processamento. Na Tabela 7.1 são apresentados os resultados VM e VP, onde na primeira coluna está a divisão dos grupos, na segunda coluna está o VM, nas demais colunas estão os resultados do cálculo do VP e da taxa de acerto, respectivamente, quando utilizado o janelamento, transformação de alargamento de contraste, operador Laplaciano, filtro de média aritmética combinada com a transformação gama e operador Sobel.

Tabela 7.1 – Volumes calculados manualmente e pelo algoritmo de crescimento de região com suas respectivas taxas de acerto para cada uma das técnicas (Janelamento, transformação de alargamento de contraste, operador Laplaciano, filtro de média aritmética com transformação gama, operador de Sobel).

Grupo	VM (cm ³)	Volume Segmentação									
		Janelamento		T. Alargamento de Contraste		Operador Laplaciano		M. Arit. com Trans. Gama		Operador Sobel	
		VP (cm ³)	Tx. Acerto (%)	VP (cm ³)	Tx. Acerto (%)	VP (cm ³)	Tx. Acerto (%)	VP (cm ³)	Tx. Acerto (%)	VP (cm ³)	Tx. Acerto (%)
1	865,45	761,81	86,00	557,66	63,61	710,62	98,33	887,48	99,99	404,09	48,42
2	1452,60	1303,19	81,89	252,65	15,81	1064,79	67,58	1844,84	78,04	366,53	22,98

Na Tabela 7.2 são apresentados os resultados de EQM para os VP apresentados na Tabela 7.1, onde na primeira coluna está a divisão dos grupos, nas demais colunas estão os resultados do cálculo do EQM, quando utilizado o janelamento, transformação de

alargamento de contraste, operador Laplaciano, filtro de média aritmética combinada transformação gama e operador Sobel.

Tabela 7.2 – Erro Quadrático Médio do VP.

Grupo	Janelamento (cm ³)	Alargamento de Contraste (cm ³)	Operador Laplaciano (cm ³)	M. Arit. com Trans. Gama (cm ³)	Operador Sobel (cm ³)
1	1,54	8,11	7,83	0,33	19,14
2	24,58	103,41	53,23	12,05	98,78


Assim, com os resultados da Tabela 7.1, onde estão contidos os valores referentes à taxa de acerto comparado com o VM, é possível observar que as imagens sem qualquer pré-processamento (imagens apenas com janelamento) tiveram 86,00% de taxa de acerto (VP igual a 761,81 cm³ enquanto o VM é igual a 865,45) para as fatias com contraste radiológico (Grupo 1) e 81,89% de taxa de acerto (VP igual a 1303,19 cm³ e VM igual a 1452,60 cm³) para as fatias sem contraste radiológico (Grupo 2). Portanto as técnicas que apresentaram resultados muito inferiores a estes, uma variação superior a 5%, considerando os dois grupos, foram descartadas da análise já que apresentaram uma taxa de acerto inferior ao que foi obtido pelas imagens sem pré-processamento.

Com esta consideração, apenas as fatias que foram pré-processadas com o filtro de média aritmética associado com a transformação de potência (Gama) são consideradas, com um resultado de 99,99% de taxa acerto (VP de 887,48 cm³ e VM igual a 865,45 cm³) para as fatias que possuíam contraste radiológico (Grupo 1) e 78,04% de taxa de acerto (VP de 1844,84 cm³ e VM igual a 1452,60 cm³) para as fatias sem contraste radiológico (Grupo 2).

E analisando o erro quadrático médio, apresentado na Tabela 7.2, a técnica que foi utilizada, o filtro de média aritmética associado com a transformação de potência teve 0,33 cm³ de erro para fatias com contraste radiológico (Grupo 1) e 12,05 cm³ de erro para as fatias sem contraste radiológico (Grupo 2), que em ambos os casos foram menores que as imagens sem pré-processamento que tiveram um EQM 1,54 cm³ para as fatias com contraste radiológico e 24,58 cm³ de erro para as fatias sem contraste radiológico.

Na Figura 7.2 têm-se alguns exemplos de fatias (com e sem contraste radiológico) segmentadas com o algoritmo de crescimento de região quando as fatias foram pré-processadas pelo filtro de média aritmética associado com a transformação gama.

Figura 7.2 – Resultado da segmentação utilizando o filtro de média aritmética com a transformação gama sobreposta com fatia do grupo com contraste radiológico (a) e (b) e sem contraste radiológico (c) e (d).



Assim, é verificado que a técnica de pré-processamento que utiliza o filtro de média aritmética associado com a transformação gama possui uma boa segmentação do fígado quanto utilizado o algoritmo de crescimento de região. E comparando as fatias com contraste radiológico e sem contraste radiológico, conforme apresentadas na Figura 7.2, o resultado é melhor para as fatias com contraste radiológico.

7.3 Automatização do algoritmo de crescimento de região (Região Retangular)

Nesta etapa foram utilizadas 882 imagens (fatias) correspondentes a cinco exames de TC, adquiridas com contraste radiológico. Cada fatia foi submetida ao processo de janelamento e, baseado nos resultados obtidos na seção 7.2 Testes preliminares de técnicas de pré-processamento, essas fatias foram pré-processadas com o filtro de média aritmética associado com a transformação gama.

Assim, para que fosse feita a avaliação da técnica de lançamento de sementes utilizando as fatias pré-processadas com o filtro de média aritmética associado com a transformação gama, foi realizada a segmentação automática com o uso da técnica de ALSRR e calculados os Volumes Automáticos – VR. Nestas mesmas fatias foram calculados os Volumes a partir da segmentação manual, nomeado de Volume Manual – VM.

Desta forma, na Tabela 7.3 são apresentados os resultados gerados do cálculo do volume automático utilizando a técnica ALSRR para calcular o volume do fígado, onde na primeira coluna estão os exames numerados de 1 a 5, na segunda coluna estão os valores de volume do fígado calculados por VM, nas demais colunas estão os resultados do cálculo do volume do fígado por VR e da taxa de acerto, respectivamente, quando utilizado o filtro de média aritmética combinado com fatias pré-processadas com a transformação gama.

Tabela 7.3 – Volume calculado de forma automática com ALSRR e de forma manual.

Exames	VM (cm ³)	VR (cm ³)	Taxa de Acerto (%)
1	865,85	857,74	99,06
2	1124,08	915,58	81,45
3	1742,56	1482,16	85,05
4	2117,23	1175,90	55,54
5	2093,47	1769,50	84,52
Média	1588,64	1240,18	81,13

Na Tabela 7.4 estão os resultados do EQM, que representam o erro médio por exame, assim, na primeira coluna estão os exames numerados de 1 a 5 e na segunda coluna estão os valores do EQM.

Tabela 7.4 – Erro quadrático médio por exame observado a partir da comparação entre as fatias segmentadas de forma manual e automática.

Exames	Erro Quadrático Médio (cm ³)
1	0,41
2	3,19
3	18,37
4	53,93
5	10,79


Com os resultados da Tabela 7.3, que contém a relação de VM e VR, foi verificado que a média da taxa de acerto dos exames foi de 81,13% (VR igual a 1240,18 cm³ e VM igual a 1588,64 cm³), sendo maior taxa de acerto foi observado no exame 1 com 99,06% (VR igual a 857,74 cm³ e VM igual a 865,85 cm³) e o menor valor da taxa de acerto foi observado no exame 4 com 55,54% (VR igual a 1175,90 cm³ e VM igual a 2117,23 cm³).

Para o EQM presente na execução do algoritmo de segmentação e volumetria automática do fígado, que está contido na Tabela 7.4, foi observado que o exame 1 foi o que apresentou o menor EQM, com $0,41 \text{ cm}^3$, e o maior EQM foi observado no exame 4, com $53,93 \text{ cm}^3$.

Assim, no exame 1, que foi obtido 99,06% de taxa de acerto, o erro foi pequeno como era de se esperar ($0,41 \text{ cm}^3$). Entretanto, considerando o exame 3 e 5 que tiveram a segunda e a terceira melhor taxa de acerto (85,05% e 84,52% respectivamente), estes tiveram o EQM acima do esperado para essa taxa de acerto ($18,37 \text{ cm}^3$ e $10,79 \text{ cm}^3$ respectivamente), sendo o EQM apenas menor que do erro encontrado para o exame 4 ($53,93 \text{ cm}^3$). Os volumes dos exames tiveram este acerto possivelmente porque no cálculo volumétrico é considerado o somatório de todos os volumes das fatias correspondentes ao fígado e comparado o valor total do volume. Divergências entre fatias não são consideradas individualmente, como acontece no cálculo do EQM, onde são considerados os erros fatia a fatia.

Deste modo, na Figura 7.3, podem ser observadas algumas imagens resultantes do processo de segmentação automática e manual, sendo as imagens da primeira coluna resultantes da segmentação manual e as imagens da segunda coluna são resultantes da segmentação automática utilizando a ALSRR.

Figura 7.3 – Em (a, c, e, g) são as fatias segmentadas manualmente, enquanto em (b, d, f, h) são as fatias segmentadas de forma automática, com o ponto de semente em destaque.



Nas fatias da Figura 7.3 podem ser observadas algumas variações nas imagens quando são segmentadas pelo especialista (Figura 7.3(a), 7.3(c), 7.3(e) e 7.3(g)) e pelo algoritmo de segmentação automática (Figura 7.3(b), 7.3(d), 7.3(f) e 7.3(h)). Foi notada uma diferença considerável entre a Figura 7.3(c) e a Figura 7.3(d), este caso pode ser explicado pela grande diferença no nível de cinza dos pixels que não foram considerados como parte do fígado pelo algoritmo de crescimento de região, por estarem com valor acima do especificado para a tolerância do algoritmo.

Assim, foi verificado que, para o algoritmo de crescimento de região utilizando a ALSRR para o lançamento de semente quando utilizado as fatias pré-processadas com o filtro de média aritmética associado com a transformação gama, teve um bom resultado considerando que os exames avaliados tiveram 81,13% de taxa de acerto na volumetria e que apenas o exame 4 teve um resultado abaixo de 80% de taxa de acerto, e alto EQM. E, ainda considerando as imagens da Figura 7.3, é verificado que a segmentação automática, no geral, preenche grande parte do fígado, se aproximando da segmentação manual, mas devido a ocorrência de grandes variações nos níveis de cinza nas fatias do fígado, o algoritmo de segmentação acabou desconsiderando alguns pixels pertencentes à região hepática causando dessa forma erro na volumetria.

7.4 Melhoria da Automatização do algoritmo de Crescimento de Região (Região Elíptica)

Como uma tentativa de melhorar a performance da ALSRR, foi desenvolvida a ALSRE, e desta forma os resultados apresentados nesta seção são referentes a comparação das duas técnicas de lançamento automático de semente para serem utilizadas no algoritmo de crescimento de região.

Para realizar a segmentação utilizando as duas técnicas de lançamento de sementes são utilizadas 2502 fatias de TC da região abdominal que tiveram a aplicação de contraste, o que corresponde a 16 exames de TC, estas fatias foram janeladas e então pré-processadas com o filtro de média aritmética e a transformação gama associada. Esta técnica de pré-processamento foi utilizada baseado nos bons resultados que foram apresentados nas seções 7.2 Testes preliminares de técnicas de pré-processamento e 7.3 Automatização do algoritmo de crescimento de região (Região Retangular).

A Tabela 7.5 apresenta os resultados gerados quando utilizado estas técnicas para o lançamento automático de semente, onde na primeira coluna estão os exames numerados de 1 a 16, na segunda coluna estão os valores de VM, na terceira, quarta e quinta colunas estão os resultados do cálculo do volume automático do fígado quando utilizado a ALSRE para fazer o lançamento automático de semente, da taxa de acerto e do EQM, respectivamente e na sexta, sétima e oitava colunas estão os resultados dos cálculos dos volumes automáticos do fígado utilizando a ALSRR para fazer o lançamento automático de semente, da taxa de acerto e do EQM, respectivamente.

Tabela 7.5 – Resultados do Volume Manual e Automático (utilizando ALSRE e ALSRR) com as respectivas taxa de acerto e EQM.

Exames	Volume Manual (cm ³)	Volume Automático					
		ALSRE			ALSRR		
		Volume (cm ³)	Tx. Acerto (%)	EQM (cm ³)	Volume (cm ³)	Tx. Acerto (%)	EQM (cm ³)
1	1093,81	1056,01	96,54	17,31	1370,28	74,72	6,39
2	755,64	867,42	85,21	2,04	845,56	88,10	2,12
3	728,41	927,56	72,66	2,95	1008,16	61,59	87,40
4	958,48	1333,42	60,88	10,47	1362,43	57,86	21,74
5	1484,48	1309,37	88,20	18,72	1379,55	92,93	105,53
6	1489,60	2069,98	61,04	14,33	2027,97	63,86	19,43
7	616,92	689,95	88,16	55,25	760,94	76,66	70,67
8	837,18	1008,28	79,56	9,39	798,24	95,35	14,81
9	409,37	397,42	97,08	160,16	298,05	72,81	211,11
10	1239,31	1911,43	45,77	86,28	1936,03	43,78	86,71
11	2523,73	1895,64	75,11	391,81	1468,83	58,20	511,52
12	1772,45	2112,22	80,83	24,17	2366,90	66,46	450,36
13	2101,53	3101,39	52,42	70,70	3629,20	27,31	1110,82
14	1184,06	1945,44	35,70	39,69	1787,87	49,00	42,20
15	1844,45	2635,40	57,12	40,46	2586,20	59,78	40,09
16	2880,52	2749,02	95,43	104,06	2665,45	92,53	122,85
Média	1370,00	1625,62	73,23	-	1643,23	67,56	-

Com o processamento das fatias apresentados na Tabela 7.5, obteve-se o volume médio de 1625,62 cm³ (73,23% de taxa de acerto), quando utilizado a ALSRE, e para a ALSRR, o volume médio foi de 1643,23 cm³ (67,56% de taxa de acerto) enquanto a média de VM foi de 1370,00 cm³.

A melhor taxa de acerto, quando utilizado a ALSRE, foi a observada no exame 9 com 97,08% (VM igual a 409,37 cm³ e o volume, quando utilizado ALSRE, foi igual a 397,42 cm³). Enquanto a pior taxa de acerto para esta técnica foi observada no exame 14 com 35,70% (VM igual a 1184,06 cm³ e o volume, quando utilizado ALSRE, foi igual a 1945,44 cm³). Para os resultados de EQM. O menor valor foi o do exame 2 com 2,04 cm³ e o pior resultado (maior valor) o do exame 11 com 391,81 cm³. Dos 16 exames apenas 3 tiveram EQM acima de 100 cm³, que foram os exames de número 9, 11 e 16.

Quando foi utilizado a técnica de ALSRR, a melhor taxa de acerto foi a observada no exame 8 com 95,35% (VM igual a 837,18 cm³ e o volume quando utilizado ALSRR foi igual a 798,24 cm³), enquanto a pior taxa de acerto para esta técnica foi observada no exame 13 com 27,31% (VM igual 2101,53 cm³ e o volume quando utilizado ALSRR foi igual a 3629,20 cm³). E observando os resultados de EQM, o menor valor foi o do exame 2 com 2,12 cm³ e o pior resultado (maior valor) o do exame 13 com 1110,82 cm³. Dos 16 exames 6 tiveram EQM acima de 100 cm³, que foram os exames de número 5, 9, 11, 12, 13 e 16.

Baseado nos resultados apresentados, foi observado que a técnica de lançamento de sementes ALSRE teve melhores resultados, tanto para a taxa de acerto quanto para o EQM, promovendo, desta maneira, um menor erro no resultado da segmentação por crescimento de região com a utilização de ALSRE para o lançamento do ponto de semente.

7.5 Técnicas de pré-processamento

7.5.1 Janelamento

Para que fosse feita a avaliação das técnicas de pré-processamento foram calculados os volumes das fatias processadas apenas com janelamento, as quais foram utilizadas na segmentação manual, nomeado de Volume Manual – VM. Estas mesmas fatias processadas apenas com janelamento foram processadas com a segmentação automática utilizando a técnica de ALSRE (a técnica ALSRE foi escolhida baseado nos resultados da seção 7.4) e calculados os Volumes Automáticos – VA.

Na Tabela 7.6 são apresentados os resultados VM e VA e o EQM em cm³, onde na primeira coluna está a divisão dos exames (de 1 a 19), na segunda coluna estão os valores de volume do fígado calculados a partir de VM, conforme descrito no Capítulo 6, na terceira coluna os valores de volume do fígado calculados a partir de VA, conforme descrito no

Capítulo 6, na quarta coluna estão os valores referente à taxa de acerto e, por fim, na quinta coluna, os resultados obtidos no cálculo do EQM com o Desvio Médio (DM) em cm^3 .


Tabela 7.6 – Dados de pré-processamento da fatia somente com o janelamento com taxa de acerto e EQM.

Exame	VM (cm^3)	Janelamento		
		VA (cm^3)	Tx. Acerto (%)	EQM \pm DM(cm^3)
1	200,74	172,41	85,89	11,24 \pm 1,97
2	1093,81	958,08	87,59	20,41 \pm 2,23
3	755,64	720,60	95,36	6,41 \pm 0,97
4	728,41	596,54	81,90	11,35 \pm 2,68
5	958,48	1038,33	91,67	16,87 \pm 2,14
6	1484,48	647,37	43,61	44,72 \pm 0,77
7	1489,59	1384,39	92,94	22,09 \pm 1,62
8	1288,87	1057,74	82,07	79,39 \pm 3,63
9	837,18	693,68	82,86	18,35 \pm 1,55
10	1468,79	1309,59	89,16	50,48 \pm 2,89
11	1503,45	1355,10	90,66	87,60 \pm 4,19
12	1239,31	772,93	62,37	74,31 \pm 6,04
13	697,73	519,01	74,39	31,98 \pm 2,84
14	2523,73	1111,09	44,03	483,92 \pm 9,67
15	1772,45	1492,78	84,22	51,11 \pm 3,48
16	2101,53	2633,76	74,67	70,10 \pm 5,44
17	1184,06	1673,95	58,63	44,79 \pm 2,81
18	1844,45	2287,82	75,96	58,52 \pm 2,30
19	2880,52	1047,66	36,37	227,04 \pm 5,49
Média	1371,22	1130,15	74,57	-

Pelos dados apresentados na Tabela 7.6, foi verificado que o EQM tem seu menor valor no exame 3 com $6,41 \pm 0,97 \text{ cm}^3$ e seu maior valor foi observado no exame 14 com $483,92 \pm 9,67 \text{ cm}^3$. Quando considerada a taxa de acerto, o melhor resultado também foi para o exame 3 que alcançou 95,36% (VA utilizando o janelamento é igual a 720 cm^3 enquanto o VM foi de $755,64 \text{ cm}^3$) e o pior desempenho foi observada no exame 19 com apenas 36,37% de acerto (VA utilizando o janelamento é igual a $1047,66 \text{ cm}^3$ enquanto o VM foi de $2880,52 \text{ cm}^3$), onde a média da taxa de acerto de VA foi de 74,57%.


Na Figura 7.4 é apresentado um exemplo de sucesso da segmentação automática, utilizando fatias segmentadas e processadas apenas com o janelamento (Figura 7.4(b)), enquanto na Figura 7.4(a) é observada a fatia original sem a sobreposição.

Figura 7.4 – (a) Fatia de TC de fígado da região abdominal, (b) sobreposição de uma fatia com janelamento que teve o fígado segmentado com a fatia original de TC. O ponto de semente está em destaque.



Na Figura 7.5 é apresentado um exemplo de insucesso da segmentação automática, utilizando fatias segmentadas usando apenas o janelamento, como técnica de pré-processamento (Figura 7.5(b)), enquanto na Figura 7.5(a) é observada a fatia original sem a sobreposição. Onde, a possível causa do insucesso apresentado na Figura 7.5(b) seja o ponto de lançamento de semente inadequado.

Figura 7.5 – (a) Fatia de TC de fígado da região abdominal, (b) sobreposição de uma fatia com janelamento que teve o fígado segmentado com a fatia original de TC.



7.5.2 Combinações de filtros e transformações de intensidades

Em seguida, antes de serem apresentados os resultados das técnicas de lançamento automático de semente para o cálculo do VA, foram testadas outras combinações de técnicas de pré-processamento utilizando as combinações citadas na Figura 6.2.

Para avaliação das combinações de técnicas de pré-processamento, VA foi calculado a partir das imagens segmentadas com crescimento de região usando ALSRE para o lançamento de sementes. A ALSRE foi escolhida, baseado nos resultados apresentados na seção 7.4 Melhoria da Automatização do algoritmo de Crescimento de Região (Região Elíptica).

As imagens com janelamento (Figura 7.6(a)) foram submetidas às seguintes combinações de técnicas de pré- processamento:

- Filtro de Média aritmética com Transformação Logarítmica (Figura 7.6(b));
- Filtro de Média Aritmética com Transformação Exponencial (Figura 7.6(c));
- Filtro de Média Aritmética com Transformação Gama (Figura 7.6(d));
- Filtro de Média Geométrica com Transformação Logarítmica (Figura 7.6(e));
- Filtro de Média Geométrica com Transformação Exponencial (Figura 7.6(f));
- Filtro de Média Geométrica Transformação Gama (Figura 7.6(g));
- Filtro de Mediana com Transformação Logarítmica (Figura 7.6(h));
- Filtro de Mediana com Transformação Exponencial (Figura 7.7(a));
- Filtro de Mediana Transformação Gama (Figura 7.7(b));
- Filtro de Wiener com Transformação Logarítmica (Figura 7.7(c));
- Filtro de Wiener com Transformação Exponencial (Figura 7.7(d));
- Filtro de Wiener Transformação Gama (Figura 7.7(e)).

Figura 7.6 – (a) Fatia janelada, (b) Filtro de Média Aritmética combinado com Transformação Logarítmica, (c) Filtro de Média Aritmética combinado com Transformação Exponencial, (d) Filtro de Média Aritmética combinado com Transformação Gama, (e) Filtro de Média Geométrica combinado com Transformação Logarítmica, (f) Filtro de Média Geométrica combinado com Transformação Exponencial, (g) Filtro de Média Geométrica combinado com Transformação Gama, (h) Filtro de Mediana combinado com Transformação Logarítmica.





Figura 7.7 – (a) Filtro de Mediana combinado com Transformação Exponencial, (b) Filtro de Mediana combinado com Transformação Gama, (c) Filtro de Wiener combinado com Transformação Logarítmica, (d) Filtro de Wiener combinado com Transformação Exponencial, (e) Filtro de Wiener combinado com Transformação Gama.



Então, foram calculados VA para cada um dos resultados das combinações para as fatias de todos os exames e comparados com VM, através do cálculo da taxa de acerto e do EQM.

A Tabela 7.7 apresenta os resultados gerados pela combinação do filtro de média aritmética com as transformações de intensidades (Figura 6.2), na primeira coluna estão os

exames numerados de 1 a 19, na segunda coluna estão os valores de volume do fígado calculados por VM, nas demais colunas estão os resultados dos cálculos de volume do fígado por VA utilizando a ALSRE para o lançamento automático de semente, da taxa de acerto e do EQM com o DM, respectivamente, quando utilizado o filtro de média aritmética combinado com imagens pré-processadas com transformação logarítmica, transformação exponencial e transformação gama.

Tabela 7.7 – Dados pré-processamento da combinação do filtro de média aritmética com: transformação logarítmica, transformação exponencial e transformação gama. Dados medidos em centímetros cúbicos.


Exame	VM (cm ³)	Filtro de Média Aritmética								
		Transf. Logarítmica			Transf. Exponencial			Transf. Gama		
		VA (cm ³)	Tx. Acerto (%)	EQM ± DM (cm ³)	VA (cm ³)	Tx. Acerto (%)	EQM ± DM (cm ³)	VA (cm ³)	Tx. Acerto (%)	EQM ± DM (cm ³)
1	200,74	1,77	0,88	35,19 ±3,12	38,51	19,18	36,56 ±3,17	231,93	84,46	24,26 ±2,74
2	1093,81	562,42	51,42	31,90 ±2,99	345,20	31,56	65,58 ±4,24	1100,33	99,40	13,23 ±1,67
3	755,64	0,00	0,00	34,49 ±2,25	183,65	24,30	32,65 ±2,25	838,37	89,05	2,41 ±0,86
4	728,41	0,11	0,02	32,53 ±2,92	21,13	2,90	33,13 ±2,92	933,04	71,91	3,02 ±0,71
5	958,48	607,51	63,38	26,58 ±1,72	31,18	3,25	56,94 ±2,14	1342,02	59,98	10,87 ±0,96
6	1484,48	50,64	3,41	83,07 ±1,37	47,36	3,19	86,44 ±1,29	1387,06	93,44	15,02 ±0,32
7	1489,59	216,31	14,52	69,03 ±3,87	1102,58	74,02	58,65 ±3,71	1261,22	84,67	48,66 ±1,66
8	1288,87	0,23	0,02	148,81 ±5,18	0,48	0,04	148,79 ±5,18	1549,61	79,77	106,40 ±5,83
9	837,18	10,62	1,27	35,48 ±2,40	3,96	0,47	36,32 ±2,48	1054,04	74,10	10,85 ±1,57
10	1468,79	8,39	0,57	129,05 ±3,82	0,36	0,02	130,18 ±3,82	1798,04	77,58	14,51 ±0,66
11	1503,45	792,38	52,70	85,09 ±4,44	95,27	6,34	125,72 ±4,41	1935,84	71,24	87,78 ±4,45
12	1239,31	7,36	0,59	124,28 ±6,02	188,58	15,22	119,29 ±6,01	819,94	66,16	83,76 ±7,07
13	697,73	359,25	51,49	40,71 ±2,20	484,15	69,39	71,31 ±1,57	1109,71	40,95	29,73 ±1,58
14	2523,73	0,00	0,00	665,60	0,30	0,01	665,50	2536,29	99,50	273,79

				$\pm 9,78$			$\pm 9,79$			$\pm 8,93$
15	1772,45	43,37	2,45	191,84 $\pm 6,39$	143,79	8,11	199,84 $\pm 6,39$	2183,56	76,81	29,99 $\pm 3,18$
16	2101,53	225,55	10,73	264,11 $\pm 11,63$	2,74	0,13	301,75 $\pm 11,28$	3202,20	47,63	72,84 $\pm 4,61$
17	1184,06	0,00	0,00	93,95 $\pm 4,51$	0,96	0,08	93,79 $\pm 4,50$	1894,70	39,98	40,96 $\pm 3,13$
18	1844,45	1441,10	78,13	79,54 $\pm 3,29$	30,71	1,66	202,85 $\pm 6,30$	2645,80	56,55	42,39 $\pm 2,26$
19	2880,52	0,00	0,00	329,06 $\pm 8,22$	0,02	0,00	329,05 $\pm 8,22$	3043,04	94,36	85,50 $\pm 7,10$
Média	1371,22	227,74	17,45	-	143,21	13,68	-	1624,57	74,08	-

Pelos resultados que são apresentados na Tabela 7.7, foi observado que apenas a combinação do filtro de média aritmética com transformação gama teve resultado satisfatório, a média da taxa de acerto é igual a 74,08% e a melhor taxa de acerto foi encontrada para o exame 14 com 99,50% (VA foi de 2536,29 cm³, enquanto o VM foi de 2523,73 cm³) e a pior taxa de acerto foi observado no exame 17 com 39,98% (VA foi de 1894,70 cm³ enquanto o VM foi de 1184,06 cm³). Já o menor EQM observado foi para o exame 3 com 2,41 $\pm 0,86$ cm³ e o maior EQM observado foi de 273,79 $\pm 8,93$ cm³ para o exame 14.

Na Figura 7.8 estão alguns exemplos de como foi o resultado da segmentação pelo algoritmo automático de crescimento de região das técnicas que tiveram seus resultados apresentados na Tabela 7.7. A primeira fatia apresentada é a original (Figura 7.8(a)), na Figura 7.8(b) está à sobreposição da fatia original com uma segmentação automática, que teve um bom resultado quando combinado o filtro de média com a transformação logarítmica, onde o ponto de semente (em destaque) foi lançado próximo à borda superior do fígado e algumas regiões, na borda direita da imagem, não foram agregadas a região segmentada. Já na Figura 7.8(c) é observado um resultado de insucesso quando utilizado o filtro de média aritmética combinado com a transformação exponencial, formando uma região que contempla a maior parte da região abdominal, caracterizando uma extrapolação dos limites do fígado. Por fim na Figura 7.8(d), é observada uma segmentação automática bastante evidente do fígado, preenchendo, quase por completo, o órgão (faltando uma pequena porção na borda direita da imagem), quando foi utilizada a combinação do filtro de média aritmética combinado com a transformação gama.

Figura 7.8 – (a) Fatia original. Sobreposição entre a fatia original e o resultado da segmentação utilizando as técnicas de pré-processamento: (b) filtro de média aritmética combinada com a transformação logarítmica, (c) filtro de média aritmética combinada com a transformação exponencial, (d) filtro de média aritmética combinada com a transformação gama. O ponto de semente está em destaque.



A Tabela 7.8 apresenta os resultados gerados pela combinação do filtro de média geométrica com as transformações de intensidades (Figura 6.2). Na primeira coluna estão os exames numerados de 1 a 19, na segunda coluna estão os valores de volumes do fígado calculados por VM, nas demais colunas estão os resultados do cálculo de volumes do fígado por VA utilizando a ALSRE para o lançamento automático de semente, da taxa de acerto e do EQM com o DM, respectivamente, quando utilizado o filtro de média geométrica combinado com imagens pré-processadas com transformação logarítmica, transformação exponencial e transformação gama.

Tabela 7.8 – Dados de pré-processamento da combinação do filtro de média geométrica com: transformação logarítmica, transformação exponencial e transformação gama. Os dados medidos em centímetros cúbicos.


Exame	VM (cm ³)	Filtro de Média Geométrica								
		Transf. Logarítmica			Transf. Exponencial			Transf. Gama		
		VA (cm ³)	Tx. Acerto (%)	EQM ±DM (cm ³)	VA (cm ³)	Tx. Acerto (%)	EQM ±DM (cm ³)	VA (cm ³)	Tx. Acerto (%)	EQM ±DM (cm ³)
1	200,74	0,00	0,00	35,29 ± 3,08	31,52	15,70	34,54 ±3,09	226,96	86,94	19,24 ±2,37
2	1093,81	508,49	46,49	35,51 ±3,22	232,84	21,29	59,73 ±4,00	1104,55	99,02	12,14 ±1,60
3	755,64	0,00	0,00	34,49 ±2,25	135,99	18,00	31,81 ±2,25	860,68	86,10	1,78 ±0,80
4	728,41	0,10	0,01	32,53 ±2,92	0,25	0,03	32,52 ±2,92	888,39	78,04	3,05 ±0,84
5	958,48	548,31	57,21	29,17 ±2,05	119,42	12,46	57,02 ±2,14	1301,38	64,22	9,33 ±0,69
6	1484,48	2,65	0,18	86,27 ±1,29	45,81	3,09	83,96 ±1,31	965,45	65,04	26,33 ±0,40
7	1489,59	170,42	11,44	70,73 ±3,87	983,30	66,01	52,54 ±3,69	1940,18	69,75	18,84 ±1,60
8	1288,87	0,07	0,01	148,82 ±5,18	0,47	0,04	148,79 ±5,18	602,93	46,78	92,54 ±4,50
9	837,18	3,50	0,42	36,18 ±2,48	3,98	0,48	36,33 ±2,48	922,34	89,83	7,67 ±0,94
10	1468,79	0,02	0,00	130,22 ±3,82	0,36	0,02	130,18 ±3,82	1168,84	79,58	33,78 ±1,35
11	1503,45	485,43	32,29	103,04 ±4,39	276,41	18,39	125,94 ±4,41	1844,72	77,30	83,06 ±4,24
12	1239,31	1,56	0,13	124,94 ±6,02	170,34	13,74	118,16 ±6,01	1135,40	91,62	67,67 ±6,83
13	697,73	284,83	40,82	39,62 ±2,91	483,41	69,28	60,90 ±1,44	1012,92	54,83	24,41 ±1,54
14	2523,73	0,00	0,00	665,60 ±9,78	0,28	0,01	665,50 ±9,79	1570,05	62,21	348,32 ±9,78
15	1772,45	67,36	3,80	188,74 ±6,39	205,28	11,58	189,68 ±6,40	2037,35	85,05	29,51 ±3,09
16	2101,53	65,03	3,09	288,51 ±11,63	6,44	0,31	301,61 ±11,34	2626,99	75,00	79,69 ±4,34
17	1184,06	0,00	0,00	93,95 ±4,51	1,09	0,09	93,77 ±4,50	1835,71	44,96	40,29 ±2,89
18	1844,45	1226,78	66,51	96,20	1,17	0,06	203,90	2615,51	58,20	38,08

				$\pm 4,50$			$\pm 6,30$			$\pm 2,06$
19	2880,52	0,00	0,00	329,06 $\pm 8,22$	0,00	0,00	329,06 $\pm 8,22$	326,80	11,35	276,80 $\pm 7,84$
Média	1371,22	177,08	13,81	-	142,02	13,19	-	1315,11	69,78	-

Pelos resultados apresentados na Tabela 7.8, foi observado que apenas a combinação do filtro de média geométrica com a transformação gama teve resultado satisfatório, uma vez que o resultado da média de valores dos volumes dos fígados, de todos os exames, calculados por VA foi de $1315,11 \text{ cm}^3$, enquanto a média de valores dos volumes dos fígados, de todos os exames calculados por VM, foi de $1371,22 \text{ cm}^3$. A melhor taxa de acerto foi observada para o exame 2 com 99,02%, o VA neste caso foi de $1104,55 \text{ cm}^3$, enquanto que o VM foi de $1093,81 \text{ cm}^3$. A pior taxa de acerto encontrada para essa combinação foi o observado no exame 17 com 44,96%. No caso do o EQM, o menor resultado foi para o exame 3 com $1,78 \pm 0,80 \text{ cm}^3$ e o maior resultado foi encontrado no exame 14 com $348,32 \pm 9,78 \text{ cm}^3$.

As imagens da Figura 7.9 exemplificam os resultados da segmentação dos casos apresentados na Tabela 7.8, onde na Figura 7.9(a) mostra a fatia original sem a sobreposição com a segmentação do fígado. Na Figura 7.9(b) mostra a sobreposição da fatia original com o resultado da segmentação automática que ocorreu quando utilizado o pré-processamento do filtro de média geométrica com a transformação logarítmica, onde o ponto de semente foi lançado na região superior do fígado, e a segmentação apresentou falhas na porção inferior do fígado. Já na Figura 7.9(c) está à sobreposição entre a fatia original e o resultado da segmentação automática quando utilizado a combinação do filtro de média geométrica com a transformação exponencial e, nesse caso, foi observado que a área de fígado segmentada pelo algoritmo cresceu em direção ao baço. Por fim, na Figura 7.9(d) está à sobreposição entre a fatia original e o resultado da segmentação automática quando utilizado a combinação do filtro de média geométrica com a transformação gama, neste caso é mostrado o sucesso da segmentação automática, cuja área segmentada ocupa quase toda a região hepática.

Figura 7.9 – (a) Fatia original. Sobreposição entre a fatia original e o resultado da segmentação utilizando as técnicas de pré-processamento: (b) filtro de média geométrica combinada com a transformação logarítmica, (c) filtro de média geométrica combinada com a transformação exponencial, (d) filtro de média geométrica combinada com a transformação gama. O ponto de semente está em destaque.



A Tabela 7.9 apresenta os resultados gerados pela combinação do filtro de mediana com as transformações de intensidades (Figura 6.2). Na primeira coluna estão os exames numerados de 1 a 19, na segunda coluna estão os valores de volumes do fígado calculados por VM, nas demais colunas estão os resultados dos cálculos de volumes do fígado por VA utilizando a ALSRE para o lançamento automático de semente, a taxa de acerto e do EQM com o DM, respectivamente, quando utilizado o filtro de mediana combinado com imagens pré-processadas com transformação logarítmica, transformação exponencial e transformação gama.

Tabela 7.9 – Dados de pré-processamento da combinação do filtro de mediana com: transformação logarítmica, transformação exponencial e transformação gama. Os dados medidos em centímetros cúbicos.


Exame	VM (cm ³)	Filtro de Mediana								
		Transf. Logarítmica			Transf. Exponencial			Transf. Gama		
		VA (cm ³)	Tx. Acerto (%)	EQM ±DM (cm ³)	VA (cm ³)	Tx. Acerto (%)	EQM ±DM (cm ³)	VA (cm ³)	Tx. Acerto (%)	EQM ±DM (cm ³)
1	200,74	1,72	0,86	35,19 ±3,12	19,28	9,60	34,87 ±3,06	238,11	81,38	20,43 ±2,37
2	1093,81	613,12	56,05	28,47 ±2,79	253,05	23,13	64,37 ±4,21	1070,99	97,91	14,16 ±1,75
3	755,64	0,00	0,00	34,49 ±2,25	149,69	19,81	31,66 ±2,25	815,08	92,13	3,06 ±0,91
4	728,41	36,81	5,05	30,95 ±3,04	17,63	2,42	32,61 ±2,92	925,09	73,00	2,96 ±0,73
5	958,48	552,31	57,62	29,00 ±1,70	177,28	18,50	69,41 ±2,14	1335,50	60,66	10,95 ±0,85
6	1484,48	35,51	2,39	81,82 ±1,29	135,97	9,16	80,31 ±1,31	1153,13	77,68	18,56 ±0,30
7	1489,59	234,23	15,72	67,59 ±3,87	1017,64	68,32	54,66 ±3,81	1943,35	69,54	18,75 ±1,69
8	1288,87	0,33	0,03	148,79 ±5,17	0,48	0,04	148,79 ±5,18	1401,90	91,23	63,19 ±3,17
9	837,18	3,82	0,46	36,09 ±2,48	5,06	0,60	36,28 ±2,48	1041,81	75,56	8,03 ±1,12
10	1468,79	0,71	0,05	130,09 ±3,82	0,37	0,03	130,17 ±3,82	1760,80	80,12	15,07 ±0,63
11	1503,45	747,84	49,74	86,00 ±4,21	97,54	6,49	126,50 ±4,41	1918,80	72,37	84,76 ±4,28
12	1239,31	31,69	2,56	123,24 ±6,03	266,11	21,47	116,49 ±6,01	550,54	44,42	99,47 ±6,43
13	697,73	409,82	58,74	37,31 ±2,42	454,00	65,07	66,81 ±1,41	1032,25	52,06	29,36 ±1,22
14	2523,73	0,00	0,00	665,60 ±9,78	1,63	0,06	665,07 ±9,80	2410,60	95,52	281,55 ±10,27
15	1772,45	131,58	7,42	181,00 ±6,33	131,53	7,42	194,24 ±6,40	2112,59	80,81	26,31 ±3,58
16	2101,53	198,87	9,46	306,74 ±12,31	51,75	2,46	301,70 ±11,28	3186,83	48,36	70,74 ±4,56
17	1184,06	0,00	0,00	93,95 ±4,51	2,19	0,18	93,67 ±4,53	1903,51	39,24	41,95 ±3,11
18	1844,45	1550,60	84,07	70,96	1,47	0,08	203,83	2642,53	56,73	41,70

				$\pm 3,27$			$\pm 6,30$			$\pm 2,14$
19	2880,52	0,00	0,00	329,06 $\pm 8,22$	0,03	0,00	329,05 $\pm 8,22$	2307,87	80,12	94,45 $\pm 7,49$
Média	1371,22	239,42	18,43	-	146,46	13,41	-	1565,86	72,04	-

Os dados apresentados na Tabela 7.9 mostram que as combinações das técnicas que utilizaram transformação logarítmica e transformação exponencial tiveram um resultado muito baixo para os valores de volumes do fígado calculado por VA, e em consequência, não sendo adequadas para utilizar como técnicas de pré-processamento. No entanto, considerando a combinação entre o filtro de mediana com a transformação gama, a média de valores dos volumes dos fígados, de todos os exames, calculados por VA foi de $1565,86 \text{ cm}^3$, enquanto que por VM foi de $1371,22 \text{ cm}^3$. O menor valor de EQM foi de $2,96 \pm 0,73 \text{ cm}^3$, no exame 4, enquanto que o maior valor de EQM foi de $281,55 \pm 10,27 \text{ cm}^3$, no exame 14. A média da taxa de acerto foi de 72,04%, sendo que o melhor resultado da taxa de acerto foi o do exame 2 com 97,91%, enquanto o pior resultado é o observado no exame 17 com 39,24%.

A fatia original sem pré-processamento é observada na Figura 7.10(a), enquanto na Figura 7.10(b) tem-se a sobreposição entre a fatia original com a imagem resultante da segmentação automática usando a fatia pré-processada com filtro de mediana e transformação logarítmica, mostrando que ficou faltando agregar à região de segmentação a porção inferior do fígado, enquanto que na Figura 7.10(c) tem-se a sobreposição entre a fatia original com a imagem resultante da segmentação automática usando a fatia pré-processada com filtro de mediana e transformação exponencial, que assim como aconteceu nas Figura 7.8(c) e Figura 7.9(c), teve uma segmentação que extrapolou a área do fígado. Por fim, a Figura 7.10(d), tem-se a sobreposição entre a fatia original com a imagem resultante da segmentação automática usando a fatia pré-processada com filtro de mediana e transformação gama, o resultado obtido com esta técnica apresentou a segmentação com maior porção fígado.

Figura 7.10 – (a) Fatia original. Sobreposição entre a fatia original e o resultado da segmentação utilizando as técnicas de pré-processamento: (b) filtro de mediana combinada com a transformação logarítmica, (c) filtro de mediana combinada com a transformação exponencial, (d) filtro de mediana combinada com a transformação gama. O ponto de semente está em destaque.



A Tabela 7.10 apresenta os resultados gerados pela combinação do filtro de Wiener com as transformações de intensidades (Figura 6.2). Na primeira coluna estão os exames numerados de 1 a 19, na segunda coluna estão os valores de volumes do fígado calculados por VM, nas demais colunas estão os resultados dos cálculos de volumes do fígado por VA utilizando a ALSRE para o lançamento automático de semente, a taxa de acerto e do EQM com o DM, respectivamente, quando utilizado o filtro de mediana combinado com imagens pré-processadas com transformação logarítmica, transformação exponencial e transformação gama.

Tabela 7.10 – Dados de pré-processamento da combinação do filtro de Wiener com: transformação logarítmica, transformação exponencial e transformação gama. Os dados medidos em centímetros cúbicos.


Exame	VM (cm ³)	Filtro de Wiener								
		Transf. Logarítmica			Transf. Exponencial			Transf. Gama		
		VA (cm ³)	Tx. Acerto (%)	EQM ±DM (cm ³)	VA (cm ³)	Tx. Acerto (%)	EQM ±DM (cm ³)	VA (cm ³)	Tx. Acerto (%)	EQM ±DM (cm ³)
1	200,74	16,68	8,31	33,53 ±3,01	38,18	19,02	35,41 ±3,16	218,51	91,15	19,51 ±2,47
2	1093,81	572,69	52,36	30,69 ±2,96	374,94	34,28	60,14 ±4,02	1029,86	94,15	16,20 ±1,84
3	755,64	0,00	0,00	34,49 ±2,25	345,85	45,77	25,51 ±2,25	781,20	96,62	4,35 ±1,01
4	728,41	13,53	1,86	31,82 ±2,92	115,80	15,90	33,10 ±2,92	861,87	81,68	3,88 ±0,63
5	958,48	627,74	65,49	24,27 ±1,51	358,92	37,45	66,08 ±2,14	1271,60	67,33	10,66 ±0,73
6	1484,48	4,08	0,27	86,01 ±1,29	74,89	5,04	84,21 ±1,29	1067,82	71,93	29,49 ±0,45
7	1489,59	215,79	14,49	67,17 ±3,87	1602,91	92,39	42,69 ±3,70	1196,40	80,32	47,03 ±1,59
8	1288,87	0,31	0,02	148,79 ±5,18	0,99	0,08	148,78 ±5,19	1319,16	97,65	104,99 ±5,73
9	837,18	3,59	0,43	36,11 ±2,48	6,08	0,73	36,27 ±2,48	969,76	84,16	6,72 ±1,15
10	1468,79	3,90	0,27	129,87 ±3,82	0,24	0,02	130,19 ±3,82	1627,97	89,16	19,19 ±0,76
11	1503,45	665,33	44,25	86,18 ±4,29	231,56	15,40	127,44 ±4,41	1810,84	79,55	84,75 ±4,20
12	1239,31	27,79	2,24	123,26 ±6,03	882,64	71,22	93,10 ±5,94	795,39	64,18	71,44 ±6,67
13	697,73	219,77	31,50	43,84 ±1,28	793,39	86,29	68,13 ±1,94	886,24	72,98	24,23 ±1,77
14	2523,73	0,00	0,00	665,60 ±9,78	1,38	0,05	665,20 ±9,80	1868,76	74,05	318,17 ±11,15
15	1772,45	83,00	4,68	186,30 ±6,39	197,95	11,17	195,00 ±6,40	1862,16	94,94	36,92 ±3,20
16	2101,53	261,69	12,45	330,36 ±12,88	3,42	0,16	301,58 ±11,29	2952,03	59,53	56,69 ±4,88
17	1184,06	0,00	0,00	93,95 ±4,51	3,55	0,30	93,51 ±4,54	1833,08	45,19	40,57 ±3,10
18	1844,45	1335,52	72,41	81,30	90,97	4,93	208,16	2573,53	60,47	44,15

				$\pm 3,32$			$\pm 6,17$			$\pm 2,17$
19	2880,52	0,02	0,00	329,05 $\pm 8,22$	0,02	0,00	329,05 $\pm 8,22$	883,50	30,67	213,70 $\pm 7,65$
Média	1371,22	213,23	16,37	-	269,67	23,17	-	1358,41	75,56	-

Com os resultados disponíveis da Tabela 7.10, é observado que as técnicas transformação logarítmica e transformação de exponencial não tiveram resultados satisfatórios para o cálculo do volume do fígado por VA. Já com o filtro de Wiener em conjunto com a transformação gama a média dos valores de volumes de fígado por VA foi de 1358,41 cm³, enquanto o VM foi de 1371,22 cm³. A média de taxa de acerto de todos os exames foi de 75,56%, já para os valores do EQM o melhor resultado foi o obtido no exame 4 com 3,88 $\pm 0,63$ cm³ e o pior resultado o obtido para o exame 14 com 318,17 $\pm 11,15$ cm³. O VA teve sua maior taxa de acerto para o exame 8 com 97,65% e o pior resultado da taxa de acerto foi o observado para o exame 19 com 30,67%, em ambos os casos o EQM foi acima de 100 cm³.

A Figura 7.11, mostra a fatia original sem pré-processamento na Figura 7.11(a), enquanto na Figura 7.11(b) tem-se a sobreposição entre a fatia original com a imagem resultante da segmentação automática usando a fatia de pré-processada com filtro de Wiener e transformação logarítmica, mostrando que ficou faltando agregar à região de segmentação a porção inferior do fígado, enquanto que na Figura 7.11(c) tem-se a sobreposição entre a fatia original com a imagem resultante da segmentação automática usando a fatia pré-processada com filtro de Wiener e transformação exponencial, que assim como aconteceu na Figura 7.10(c), Figura 7.9(c) e Figura 7.8(c), ocorreu uma segmentação que extrapolou a área do fígado. Por fim, na Figura 7.11(d), tem-se a sobreposição entre a fatia original com a imagem resultante da segmentação automática usando a fatia pré-processada com filtro de Wiener e transformação gama, o resultado obtido com esta técnica apresentou a segmentação com maior porção fígado.

Figura 7.11 – (a) Fatia original. Sobreposição entre a fatia original. (b) Fatia de TC sobreposta com a segmentação do fígado quando utilizado filtro de Wiener associado com a transformação logarítmica para realizar o pré-processamento. (c) Utilização do filtro de Wiener associado com a transformação exponencial, (d) filtro de mediana combinada com a transformação gama. O ponto de semente está em destaque.



A Tabela 7.11 apresenta os resultados gerados pelas transformações de intensidades (Figura 6.2). Na primeira coluna estão os exames numerados de 1 a 19, na segunda coluna estão os valores de volumes do fígado calculados por VM, nas demais colunas estão os resultados dos cálculos de volumes do fígado por VA utilizando a ALSRE para o lançamento automático de semente, a taxa de acerto e do EQM com o DM, respectivamente, quando utilizado a transformação de alargamento de contraste, o operador Laplaciano e o Operador Sobel.

Tabela 7.11 – Dados de pré-processamento da transformação de alargamento de contraste, do operador Laplaciano e do operador Sobel.

Exame	VM (cm ³)	Transf. Alarg. Contraste			Operador Laplaciano			Operados Sobel		
		VA (cm ³)	Tx. Acerto (%)	EQM ±DM (cm ³)	VA (cm ³)	Tx. Acerto (%)	EQM ±DM (cm ³)	VA (cm ³)	Tx. Acerto (%)	EQM ±DM (cm ³)
1	200,74	1,56	0,78	34,71 ±3,05	17,80	8,87	31,58 ±3,06	0,26	0,13	35,22 ±3,08


2	1093,81	4,80	0,44	65,56 ±4,30	199,17	18,21	48,82 ±3,86	0,40	0,04	65,94 ±4,30
3	755,64	9,45	1,25	33,82 ±2,28	123,35	16,32	25,10 ±1,60	0,59	0,08	34,45 ±2,25
4	728,41	3,66	0,50	32,34 ±2,93	177,11	24,31	22,06 ±3,13	0,53	0,07	32,50 ±2,92
5	958,48	9,35	0,98	54,91 ±2,28	250,54	26,14	38,06 ±1,59	0,42	0,04	55,43 ±2,27
6	1484,48	4,22	0,28	86,15 ±1,30	78,78	5,31	84,00 ±1,63	9,50	0,64	86,16 ±1,30
7	1489,59	2,07	0,14	79,82 ±3,87	90,37	6,07	74,76 ±3,96	0,47	0,03	79,93 ±3,87
8	1288,87	4,37	0,34	148,49 ±5,18	156,82	12,17	134,18 ±5,20	0,35	0,03	148,79 ±5,18
9	837,18	21,10	2,52	35,68 ±2,61	353,92	42,27	20,42 ±2,91	1,59	0,19	36,40 ±2,48
10	1468,79	1,55	0,11	130,02 ±3,81	300,61	20,47	124,33 ±2,61	127,64	8,69	139,25 ±3,82
11	1503,45	6,59	0,53	118,97 ±4,50	388,14	31,32	104,71 ±3,80	5,20	0,42	119,42 ±4,42
12	1239,31	8,70	0,70	123,25 ±6,08	84,10	6,79	123,97 ±6,82	34,66	2,80	130,58 ±6,48
13	697,73	0,79	0,11	56,78 ±0,45	54,77	7,85	53,52 ±0,47	0,17	0,02	56,83 ±0,45
14	2523,73	30,19	1,20	638,53 ±9,58	532,68	21,11	542,58 ±11,10	1,98	0,08	664,81 ±9,79
15	1772,45	5,75	0,32	196,42 ±6,40	182,12	10,28	175,63 ±7,16	1,70	0,10	196,81 ±6,39
16	2101,53	43,03	2,05	296,66 ±12,12	629,56	29,96	216,94 ±12,75	6,24	0,30	301,63 ±11,43
17	1184,06	54,50	4,60	90,18 ±5,24	963,94	81,41	44,56 ±3,09	2,86	0,24	93,76 ±4,54
18	1844,45	137,63	7,46	191,60 ±8,04	1054,15	57,15	89,84 ±3,98	2,38	0,13	203,86 ±6,32
19	2880,52	22,04	0,77	324,82 ±7,98	198,59	6,89	309,25 ±8,24	1,47	0,05	328,88 ±8,24
Média	1371,22	19,54	1,31	-	307,18	22,49	-	10,44	0,74	-

Com os resultados apresentados na Tabela 7.11, é observado que as técnicas transformação de alargamento de contraste, operador Laplaciano e operador Sobel não tiveram resultados satisfatórios para o cálculo do volume do fígado por VA.

As imagens da Figura 7.12 exemplificam como é o resultado da segmentação dos casos apresentados na Tabela 7.11, onde na Figura 7.12(a) mostra a fatia original sem a sobreposição com a segmentação do fígado. Na Figura 7.12(b) mostra a sobreposição da fatia original com o resultado da segmentação automática que ocorreu quando utilizado o pré-processamento da transformação de alargamento de contraste, onde o ponto de semente foi lançado na região mediana do fígado, e praticamente não houve segmentação. Já na Figura 7.12(c) está à sobreposição entre a fatia original e o resultado da segmentação automática quando utilizado o operador Laplaciano, e neste caso, foi observado que a área de fígado segmentada pelo algoritmo ocorreu apenas na porção inferior do fígado. E por fim na Figura

7.12(d) está à sobreposição entre a fatia original e o resultado da segmentação automática quando utilizado o operador Sobel onde é observado que não ocorreu à segmentação.

Figura 7.12 – (a) Fatia de TC da região abdominal. Sobreposição da segmentação do fígado com a fatia de TC da região abdominal sendo pré-processada com: (b) Transformação de alargamento de contraste, (c) operador Laplaciano e (d) Operador Sobel. O ponto de semente está em destaque.



De forma geral, analisando os resultados apresentados destas técnicas de pré-processamento, pode ser observado que o VA do exame não deve ser considerado sozinho, uma vez que esse volume calculado nem sempre representa uma baixa taxa de erro por fatia, como é o caso observado na Tabela 7.7, que para o exame 14, na combinação de filtro de média aritmética com a transformação gama, teve uma taxa de acerto de 99,50%. Porém, seu EQM foi de $273,79 \text{ cm}^3$, assim como na Tabela 7.10, no exame de número 8, a taxa de acerto foi de 97,65%, enquanto o EQM foi de $104,99 \text{ cm}^3$.

Também foi observado que os filtros de suavização (filtro de média aritmética, filtro de média geométrica, filtro de mediana, filtro de Wiener) quando combinados com a transformação gama, obtiveram os melhores resultados na segmentação por crescimento de

região e taxas de acerto do volume do fígado, e assim, na Tabela 7.12 é observado um resumo destes resultados de taxa de acerto e desvio padrão (DP) da taxa de acerto.

Tabela 7.12 – Resumo das técnicas de pré-processamento que tiveram melhores resultados, usando ALSRE.

Técnica de Pré-Processamento	Tx. Acerto (%)	DP da Tx. de Acerto
Janelamento	74,57	$\pm 17,64$
Média Aritmética com T. Gama	74,08	$\pm 18,43$
Média Geométrica. com T. Gama	69,78	$\pm 20,82$
Mediana com T. Gama	72,04	$\pm 17,48$
Wiener com T. Gama	75,56	$\pm 18,06$

Assim, foi possível verificar pelos resultados apresentados na Tabela 7.12 uma pequena variação entre as combinações de filtros de suavização com a transformação gama, variando a taxa de acerto de 69,78% até 75,56% (pouco mais de 5%).

E também os dois melhores resultados apresentados na Tabela 7.12, em ordem decrescente, considerando os valores da média da taxa de acerto, foi para a combinação do filtro de Wiener com a transformação gama com $75,56 \pm 18,06\%$ e em sequência as fatias que somente foram janeladas, com a taxa de acerto igual a $74,57 \pm 17,64\%$.

Já quando analisadas as médias de VA para todos os exames comparados com as médias de VM de todos os exames ($1371,22 \text{ cm}^3$), a porcentagem de acerto aumenta, conforme mostra a Tabela 7.13.

Tabela 7.13 – Resultados das médias de VA comparado com a média de VM. Processadas com ALSRE.

Técnica de Pré-Processamento	VA (cm^3)	Acerto (%)
Janelamento	1130,15	82,42
Média Aritmética com T. Gama	1624,57	81,52
Média Geométrica. com T. Gama	1315,11	95,91
Mediana com T. Gama	1565,86	85,81
Wiener com T. Gama	1358,41	99,07

Assim, analisando os resultados da Tabela 7.13, a média de VA das fatias pré-processadas com filtro de Wiener e função de transformação de intensidade gama tiveram 99,07% de taxa de acerto quando comparado com o VM, enquanto a média das fatias que foram processadas apenas com o janelamento tiveram 82,42% de taxa de acerto.

7.6 Resultados utilizando as diferentes técnicas de lançamento de semente

A partir da utilização do filtro de média aritmética combinado com a transformação gama foi realizada a segmentação automática das fatias de TC que continham partes do fígado utilizando o algoritmo de crescimento de região, variando a área de lançamento de semente conforme as três técnicas propostas no Capítulo 6: 6.6.2 Área de lançamento de semente em região retangular; 6.6.3 Área de lançamento de semente em região elíptica; e 6.6.4 Área de lançamento de semente em região circular.

Os resultados da aplicação destas técnicas foram resumidos na Tabela 7.14, onde a primeira coluna está à numeração dos exames, na segunda coluna os resultados dos VM dos fígados, na terceira coluna estão os resultados da VA quando utilizado segmentação automática com ALSRR, na quarta coluna estão os resultados da taxa de acerto com a técnica ALSRR, na quinta coluna estão o resultado dos VA quando utilizado segmentação automática com ALSRE, na sexta coluna estão os resultados da taxa de acerto com a técnica ALSRE, na sétima coluna estão os resultados do VA com ALSRC e por fim, na oitava coluna, estão os resultados das taxas de acerto com a técnica ALSRC.

Tabela 7.14 – Volumes dos fígados calculados manualmente e automaticamente com as respectivas técnicas para o lançamento de sementes: ALSRR, ALSRE e ALSRC.

Exames	VM (cm ³)	Volume Automático					
		ALSRR (cm ³)	Tx. Acerto (%)	ALSRE (cm ³)	Tx. Acerto (%)	ALSRC (cm ³)	Tx. Acerto (%)
1	200,74	341,33	29,96	273,48	63,76	206,98	96,89
2	1093,81	1370,28	74,72	1056,01	96,54	1072,07	98,01
3	755,64	845,56	88,10	867,42	85,21	869,86	84,88
4	728,41	892,38	77,49	927,56	72,66	910,80	74,96
5	958,48	1362,43	57,86	1333,42	60,88	1372,57	56,80
6	1484,48	1248,15	84,08	1309,37	88,20	1083,69	73,00
7	1489,60	2027,97	63,86	2069,98	61,04	1840,89	76,42
8	1288,87	3436,58	66,64	1362,30	94,30	1074,77	83,39
9	837,18	798,24	95,35	1008,28	79,56	853,18	98,09
10	1468,80	3677,42	50,37	1705,46	83,89	1336,54	91,00
11	1503,45	2139,79	57,67	1429,30	95,07	743,78	49,47
12	1239,31	1936,03	43,78	1911,43	45,77	1636,85	67,92
13	697,72	1143,52	36,11	1136,57	37,10	1005,28	55,92
14	2523,73	1468,83	58,20	1895,64	75,11	1846,99	73,18
15	1772,45	2105,87	81,19	2112,22	80,83	1919,15	91,72

16	2101,53	3057,34	54,52	3101,39	52,42	2936,03	60,29
17	1184,06	1787,87	49,01	1945,31	35,71	1906,58	38,98
18	1844,45	2586,20	59,78	2635,40	57,12	2751,36	50,83
19	2880,52	2665,45	92,53	2749,02	95,43	2531,25	87,87
Média	1371,22	1836,38	64,27	1622,61	71,61	1468,35	74,19

Com os resultados da Tabela 7.14 foi observado que os melhores resultados da média da taxa de acerto em ordem decrescente foram 74,19% para a técnica ALSRC, 71,61% para a técnica ALSRE e 64,27% para a técnica ALSRR. Já quando analisadas as médias de VA para todos os exames, comparadas com as médias de VM de todos os exames (1371,22 cm³), a porcentagem de acerto aumenta, conforme mostra a Tabela 7.15.

Tabela 7.15 – Resultados das médias de VA comparado com a média de VM e pré-processadas com media mais gama.

Segmentação	VA (cm ³)	Acerto (%)
ALSRR	1836,38	66,08
ALSRE	1622,61	81,67
ALSRC	1468,35	92,92

Assim, pela análise das Tabela 7.14 e Tabela 7.15, os melhores acertos em relação à porcentagem de taxa de acerto e porcentagem de acerto, entre as médias de VM e VA, são observados para a técnica de segmentação que utiliza ALSRC, mostrando assim, a sua superioridade em relação às demais técnicas testadas (ALSRR e ALSRE). Porém, como estes resultados foram obtidos a partir de imagens pré-processadas com filtro de média aritmética e função de transformação de intensidade gama, outros testes foram realizados, desta vez utilizando segmentação com ALSRC e imagens pré-processadas com Filtro de Wiener e função de transformação de intensidade gama.

A escolha das imagens pré-processadas com filtro de Wiener ao invés de filtro de média aritmética, se deu baseada nos resultados apresentados nas Tabela 7.12 e Tabela 7.13, onde os resultados de porcentagem de taxa de acerto e a porcentagem de acerto entre as médias de VM e VA se mostraram superiores, quando utilizado imagens pré-processadas com o filtro de Wiener.

A Tabela 7.16 apresenta o resumo dos resultados de VA e taxas de acertos para as fatias que foram pré-processadas com filtro de Wiener e transformação gama e utilizando a técnica de segmentação ALSRC e também ALSRE, assim como os resultados para as fatias

que foram pré-processadas com filtro de média aritmética e transformação gama utilizando a técnica de segmentação ALSRC e também a ALSRE.

Tabela 7.16 – Resultados das médias de VA utilizando ALSRC, ALSRE e ALSRR em fatias pré-processadas com filtro de média aritmética com transformação gama e também o resultados das médias de VA utilizando ALSRC, ALSRE em fatias pré-processadas com filtro de Wiener com transformação gama.

Filtro de Pré-processamento	Técnica de Segmentação Aut.	VA (cm ³)	Acerto (%)
Filtro de Média Aritmética com Transformação Gama	ALSRR	1836,38	66,08
	ALSRE	1622,61	81,67
	ALSRC	1468,35	92,92
Filtro de Wiener com Transformação Gama	ALSRE	1358,41	75,56
	ALSRC	1290,85	94,14

Pela análise da Tabela 7.16, os melhores acertos em relação à porcentagem de taxa de acerto e porcentagem de acerto entre as médias de VM (1371,22 cm³) e VA, são observados para a técnica de segmentação que utiliza ALSRC, quando utilizadas imagens pré-processadas com o filtro de Wiener e a função de transformação gama, que teve 94,14% de taxa de acerto. Isto mostra a superioridade da técnica ALSRC em relação às demais técnicas de lançamento de semente (ALSRR e ALSRE) e pré-processamento testadas (média aritmética com a função de transformação gama).

Na Tabela 7.17 são apresentados os resultados dos valores de EQM com DM que foram calculados considerando os resultados dos volumes obtidos para cada um dos três modos diferentes de lançamento automático de sementes (ALSRR, ALSRE e ALSRC), utilizado no algoritmo de crescimento de região para realizar a segmentação do fígado em fatias que foram pré-processadas com filtro de média aritmética e transformação gama. E também os valores de EQM com DM para a técnica de lançamento de semente automático ALSRC quando as fatias foram pré-processadas com filtro de Wiener e transformação gama, nomeado de ALSRCw.

Assim na primeira coluna da Tabela 7.17 está à numeração dos exames, enquanto que na segunda, terceira e quarta colunas estão os valores de EQM com DM quando utilizadas as técnicas ALSRR, ALSRE e ALSRC para o lançamento de sementes em fatias que foram pré-processadas com filtro de média aritmética e a função de transformação de intensidade gama. E por fim, na quinta coluna estão os resultados do cálculo do EQM com DM quando utilizado a técnica ALSRC em fatias que foram pré-processadas com filtro de Wiener e função de transformação de intensidade gama para o lançamento de sementes.


Tabela 7.17 – EQM para as técnicas de lançamento de semente automático ALSRR, ALSRE, ALSRC em fatias pré-processadas com filtro de média aritmética com transformação gama e filtro de Wiener com transformação gama.

Exames	EQM			
	F. Média Aritmética + T. Gama			F. Wiener + T. Gama
	ALSRR \pm DM (cm ³)	ALSRE \pm DM (cm ³)	ALSRC \pm DM (cm ³)	ALSRCw \pm DM (cm ³)
1	26,85 \pm 2,72	22,26 \pm 2,63	26,15 \pm 2,33	23,41 \pm 2,16
2	6,39 \pm 1,28	17,31 \pm 2,14	16,78 \pm 2,09	22,68 \pm 2,32
3	2,12 \pm 0,73	2,04 \pm 0,77	1,76 \pm 0,67	1,88 \pm 0,69
4	3,40 \pm 0,81	2,95 \pm 0,82	3,29 \pm 0,84	3,40 \pm 0,75
5	21,74 \pm 1,62	10,47 \pm 1,34	21,02 \pm 1,72	19,85 \pm 1,65
6	16,81 \pm 2,27	18,72 \pm 2,46	22,46 \pm 2,80	32,41 \pm 3,47
7	19,43 \pm 1,99	14,33 \pm 1,94	16,28 \pm 1,83	11,92 \pm 1,58
8	1373,02 \pm 23,12	89,95 \pm 4,60	86,17 \pm 4,01	83,34 \pm 3,97
9	14,81 \pm 2,00	9,39 \pm 1,60	13,08 \pm 1,85	11,38 \pm 1,65
10	1844,17 \pm 24,76	25,16 \pm 2,63	35,78 \pm 3,06	49,20 \pm 3,68
11	444,37 \pm 4,48	52,95 \pm 4,47	85,08 \pm 4,43	85,94 \pm 4,20
12	86,71 \pm 7,11	86,28 \pm 1,96	88,96 \pm 4,01	81,92 \pm 3,82
13	28,52 \pm 2,84	28,63 \pm 2,79	30,76 \pm 2,80	20,87 \pm 2,40
14	511,52 \pm 9,58	391,81 \pm 8,60	335,55 \pm 6,17	325,00 \pm 5,83
15	33,92 \pm 3,32	24,17 \pm 2,76	32,83 \pm 2,95	68,50 \pm 4,41
16	73,02 \pm 4,40	70,70 \pm 4,26	77,00 \pm 4,58	67,64 \pm 3,98
17	42,48 \pm 3,15	39,95 \pm 3,22	39,20 \pm 3,05	54,28 \pm 3,47
18	40,09 \pm 3,05	40,46 \pm 3,22	117,38 \pm 4,25	133,07 \pm 4,54
19	122,85 \pm 5,43	104,06 \pm 4,91	113,64 \pm 5,45	208,43 \pm 8,35

Dessa maneira, com os resultados apresentados na Tabela 7.17, pode ser observado que o menor valor de EQM de todas as técnicas é o apresentado no exame 3, e dentre eles, o que possui o melhor resultado é observado para a técnica ALSRCw com $1,88 \pm 0,69 \text{ cm}^3$. Já o pior valor de EQM, considerando todas as técnicas, é o do exame 10 com $1844,17 \pm 24,76 \text{ cm}^3$ quando utilizado ALSRR.


Para comparar visualmente os resultados da segmentação do fígado, é apresentada uma sequência de imagens da região abdominal sobreposta com a segmentação de fígado quando utilizado a técnica ALSRC com as fatias pré-processadas com filtro de média aritmética e transformação gama (Figura 7.13) e quando as fatias são pré-processadas com filtro de Wiener e transformação gama (Figura 7.14).

Figura 7.13 – Sequência de imagens segmentadas pela técnica de crescimento de região quando utilizado a ALSRC sobreposta com as fatias originais.



A sequência de imagens da Figura 7.13 mostra que a técnica de segmentação com lançamento de semente ALSRC, quando utilizadas às fatias que foram pré-processadas com o filtro de média aritmética e transformação gama, segmentou o fígado quase na sua totalidade, faltando algumas pequenas regiões para ser agregado à região segmentada do fígado.

Figura 7.14 – Sequência de imagens segmentadas pela técnica de crescimento de região quando utilizado a ALSRCw sobreposta com as fatias originais.



Agora, analisando a sequência de imagens da Figura 7.14, pode ser observado que a técnica de segmentação com lançamento de semente ALSRCw, quando utilizadas as fatias que foram pré-processadas com o filtro de Wiener e função de transformação de intensidade gama, realizou uma segmentação do fígado de forma superior à apresentada para a técnica de segmentação ALSRC quando utilizadas as fatias que foram pré-processadas com o filtro de média aritmética e função de transformação de intensidade gama (Figura 7.13).

Apesar de ambas as técnicas apresentarem resultados acima de 90% para a média da taxa de acerto, a técnica ALSRCw, quando utilizada em fatias que foram pré-processadas com o filtro de Wiener e a função de transformação de intensidade gama, teve melhores resultados para a segmentação automática do fígado.

7.7 Considerações Finais

Com os resultados das técnicas apresentadas neste capítulo, foi possível observar a variação promovida pelas técnicas de pré-processamento, inclusive elegendo a técnica combinada de filtro de Wiener com transformação gama, como a técnica que teve resultados melhores que os obtidos com as outras combinações. Também foi observado o melhor resultado da técnica de lançamento de sementes automática ALSRC frente às demais desenvolvidas.

Capítulo 8 CONCLUSÕES

O objetivo deste trabalho foi de realizar a segmentação do fígado e calcular seu volume automaticamente. Para isto, foi imprescindível a avaliação de técnicas de pré-processamento, para que fossem reduzidos ruídos e também para melhorar o contraste da imagem a fim de auxiliar o desempenho da técnica de segmentação.

A técnica de segmentação utilizada, por crescimento de região, depende de parâmetros de difícil automatização, que são a área de lançamento de semente e também da escolha adequada do valor da semente. Durante este processo, este trabalho propôs metodologias de seleção de área de lançamento de semente e avaliou o desempenho do algoritmo de crescimento de região a partir de áreas com diferentes formatos.

Quando selecionadas áreas circulares para o lançamento de semente, o desempenho do algoritmo de crescimento de região mostrou-se superior, e isto se deve a possibilidade de eliminação de pixels pertencentes a estruturas ósseas (costelas) presentes nas fatias de TC de fígado, que anatomicamente fazem fronteira com parte do fígado, e desta forma, influenciam no valor da semente quando esta é lançada sobre estas áreas com partes ósseas.

Além da seleção da área adequada para o lançamento de semente, o contraste entre o fígado e os órgãos adjacentes também influencia no desempenho do algoritmo de segmentação e na escolha do valor da semente, uma vez que a técnica por crescimento de região é baseada em semelhanças de pixels vizinhos e cuja semelhança se dá pelos seus valores, ou seja, intensidades de cinza. Desta forma, a avaliação de técnicas de pré-processamento de realce de contraste e redução de ruído (principalmente ruído quântico), foram importantes na tentativa de melhorar e aprimorar o desempenho da segmentação. Com os testes de pré-processamento foi possível verificar a eficiência do filtro de Wiener, uma vez que este é um filtro de bom desempenho para ruído quântico, aliado a transformação gama que altera o contraste a partir de um determinado valor de pixel presente na imagem.

A segmentação manual das imagens foi fundamental para quantificação dos processos de automatização da segmentação e também validação do cálculo do volume hepático automático, uma vez que, a única maneira de validar as medidas automáticas seria através de medidas na própria imagem. Os volumes resultantes do processo automático ficaram dentro do esperado, segundo a literatura apresentada no Capítulo 2. Porém, foi possível observar que

o resultado adequado volume automático é dependente da segmentação, que por sua vez depende do pré-processamento e, no caso do algoritmo de crescimento de região, da área de lançamento de semente. Como pode ser visto nos resultados apresentados no Capítulo 7, onde os resultados dos volumes automáticos variaram com as técnicas de pré-processamento e também com o formato da área de lançamento de semente.

Por fim, a automatização da segmentação do fígado por crescimento de região mostrou-se uma técnica robusta, principalmente quando utilizado seleção automática de área de lançamento de semente circular. A seleção automática de área de lançamento de semente foi uma contribuição para o algoritmo de crescimento de região implementado para este projeto. Além disso, com a área de lançamento de semente circular, é possível eliminar da região de interesse estruturas que não fazem parte do fígado e, portanto, foi possível aumentar a chance de escolha de valores adequados para o ponto de semente.

Como trabalho futuro é sugerido dar continuidade ao projeto, para que o mesmo se torne um software útil aos médicos radiologistas para o auxílio ao diagnóstico. É sugerida a melhoria na técnica de pré-processamento para melhor aguçamento e suavização das intensidades do fígado de forma que seja obtida uma melhor segmentação hepática, e também adaptação da técnica de segmentação para que seja utilizada nas três fases (arterial, portal e de equilíbrio), para que assim possa ser adicionada a funcionalidade de detecção de patologias nos tecidos hepáticos.

REFERÊNCIAS

1. INSTITUTO NACIONAL DE CÂNCER JOSÉ ALENCAR GOMES DA SILVA, **Estimativa 2014: Incidência de Câncer no Brasil**. Rio de Janeiro, 2014.
2. INSTITUTO NACIONAL DE CÂNCER JOSÉ ALENCAR GOMES DA SILVA, **Câncer de fígado**. 2015. Disponível em: <http://www.inca.gov.br/conteudo_view.asp?id=330>. Acesso em: 28 jan. 2015.
3. AMERICAN CANCER SOCIETY. **Survival rates for liver cancer**. 2015. Disponível em: <http://www.cancer.org/cancer/livercancer/detailedguide/liver-cancer-survival-rates>>. Acesso em: 28 jan. 2015.
4. HUANG, Y. L.; CHEN, J.H.; SHEN, W.C. Diagnosis of hepatic tumors with texture analysis in nonenhanced computed tomography images. **Acad Radiol**, Reston., v. 13, n. 6, 2006.
5. GILBERT, F. J.; LENKE, H. Computer-aided diagnosis. **The British Journal of Radiology**, London, v. 78, n.1, 2005.
6. HUANG, C. et al. Automatic Liver Detection and Segmentation from 3D CT images: a hybrid method using statistical pose model and probabilistic atlas. **Int J CARS**, Berlin, v. 8, n. 1, 2013.
7. GUYTON, A. C.; HALL, J. E. **Textbook of medical physiology**, 11th ed, Elsevier Saunders, Philadelphia, 2006.
8. HSIEH, J. **The computed tomograph principles, design, artifacts, and recent advances**, 2 ed., SPIE and Wiley-Interscience, Bellingham, v.1, n.1, 2009.
9. GONZALEZ, R. C.; WOODS R.E. **Processamento digital de imagens**, 3.ed., Pearson Prentice Hall, São Paulo, 2010.
10. HSIEN-WEN, C.; TZU-CHAO, C. Automatic computation of liver volume from living donor for liver transplantation procedure. **Image and Graphics (ICIG), 2013 Seventh International Conference on**, Qingdao, v.1, n.1, 2013.
11. ZHENG-RONG, S.; LU-NAN Y.; CHENG-YOU, D. Donor safety and remnant liver volume in living donor liver transplantation.. **World J Gastroenterol**, Beijing, v. 18, n. 48, 2012.
12. YEN-WEI, C. et al. Computer-aided liver surgical planning system using CT volumes. **Conf Proc IEEE Eng Med Biol Soc**. Piscataway, v.1, n.1, 2013.
13. GAMBINO, O. et al. Automatic Volumetric Liver Segmentation Using Texture Based Region Growing. **Complex, Intelligent and Software Intensive Systems (CISIS)**, Krakow, v.1, n.1, 2010.
14. WU, J. et al. Texture feature based automated seeded region growing in abdominal MRI segmentation. **Biomedical Engineering and Informatics (BMEI)**, Sanya, v.2, n.1, 2008.
15. YANHUI, S.; KUNYU T.; JIAN W. A new seeded region growing algorithm for large object segmentation. **Biomedical Engineering and Informatics (BMEI)**, Shanghai, v.1, n.1, 2011.
16. POHLE, R.; TOENNIES K. D. Segmentation of medical images using adaptive region growing. **Medical Imaging SPIE**, San Diego, v.2, n. 27, 2001.
17. YUFEI C. et al. Liver Segmentation from CT Images Based on Region Growing Method. **3rd International Conference on Bioinformatics and Biomedical Engineering**, Beijing, v.1, n.11, 2009.
18. JAYANTHI, M.; KANMANI B. Extracting the Liver and Tumor from Abdominal CT Images. **Signal and Image Processing (ICSIP)**, Jeju Island , v.1, n.1, 2014.

19. KUMAR, S. S.; MONI R. S.; RAJEESH J. Automatic liver and lesion segmentation: a primary step in diagnosis of liver diseases. **Signal, Image and Video Processing**, London, v.7, n.1, 2013.
20. ZHENNAN, Y. et al. Based on pre-treatment and region growing segmentation method of liver. **Image and Signal Processing (CISP)**, Yantai, v.3, n.1, 2010.
21. JUNBIN, H. et al. Based on statistical analysis and 3D region growing segmentation method of liver. **3rd International Conference on Advanced Computer Control (ICACC)**, Harbin, v.1, n.1, 2011.
22. ABD-ELAZIZ, O. F.; SAYED, M. S.; ABDULLAH M. I. Liver tumors segmentation from abdominal CT images using region growing and morphological processing. **International Conference on Engineering and Technology (ICET)**, Cairo, v.1, n.1, 2014.
23. CAMPADELLI, P.; CASIRAGHI, E.; LOMBARDI, G. Automatic liver segmentation from abdominal CT scans. **14th International Conference on Image Analysis and Processing**, Modena, v.1, n.1, 2007.
24. WENHAN, W.; XIHE, G. A high-speed method for liver segmentation on abdominal CT image. **6th International Conference on Information Science and Service Science and Data Mining (ISSDM)**, Taipei, v.1, n.1, 2012.
25. MOSTAFA, A. et al. Evaluating the effects of image filters in CT Liver CAD system. **IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI)**, Hong Kong, v.1, n.1, 2012.
26. SUZUKI, K. et al. Quantitative radiology: automated CT liver volumetry compared with interactive volumetry and manual volumetry. **AJR Am J Roentgenol**, Leesburg, v.197, n.4, 2011.
27. ABDEL-MASSIEH, N. H.; HADHOUD, M. M.; MOUSTAFA, K.A. A fully automatic and efficient technique for liver segmentation from abdominal CT images. **7th International Conference on Informatics and Systems (INFOS)**, Cairo, v.1, n.1, 2010.
28. SUZUKI, K. et al., Computer-aided measurement of liver volumes in CT by means of geodesic active contour segmentation coupled with level-set algorithms. **Med Phys**, Maryland, v.37, n.5, 2010.
29. MASSOPTIER, L.; CASCIARO, S. A new fully automatic and robust algorithm for fast segmentation of liver tissue and tumors from CT scans. **European Radiology**, Vienna, v.18, n.8, 2008.
30. E-Liang, C. et al., An automatic diagnostic system for CT liver image classification. **IEEE Transactions on Biomedical Engineering**, v.45, n.6, 1998.
31. SHENGJUN, Z.; YUANZHI, C. Liver segmentation with shape-intensity prior level set combining probabilistic atlas and probability map constrains. **International Conference on Progress in Informatics and Computing (PIC)**, Shanghai, v.1, n.1, 2014.
32. LINGURARU, M.G. et al. Automated segmentation and quantification of liver and spleen from CT images using normalized probabilistic atlases and enhancement estimation. **Med Phys**, Maryland, v.37, n.2, 2010.
33. CHANGYANG, L. et al. Fully automated liver segmentation for low- and high-contrast CT volumes based on probabilistic atlases. **17th IEEE International Conference on Image Processing (ICIP)**, Hong Kong, v.1, n.1, 2010.
34. FORUZAN, A.H., et al. Liver segmentation by intensity analysis and anatomical information in multi-slice CT images. **IJCARS**, Barcelona, v.4, n.3, 2009.
35. AKRAM, M. U.; AASIA, K.; KHALID, I. An automated System for Liver CT Enhancement and Segmentation. **GVIP**, Delaware, v.10, n.4, 2010.

36. SHAOHUA, S.; YAN, S. Key techniques research in computer-aided hepatic lesion diagnosis system based on multi-phase CT images. **4th International Congress on Image and Signal Processing (CISP)**, Shanghai, v.1, n.1, 2011.
37. CHARTRAND, G. et al. Semi-automated liver CT segmentation using Laplacian meshes. **IEEE 11th International Symposium on in Biomedical Imaging (ISBI)**, Beijing, v.1, n.1, 2014.
38. HEIMANN, T. et al. Comparison and Evaluation of Methods for Liver Segmentation From CT Datasets. **IEEE Transactions on Medical Imaging**, New York, v.28, n.8, 2009.
39. BRONZINO, J.D., **Biomedical Engineering Handbook**. 2 ed., London, CRCPress LLC, 2000.
40. LEÃO, M. P. V.; MACEDO, V. G. Comparação entre os Métodos Analíticos e Iterativo na Reconstrução de Imagens Tomográficas. **XXIV Congresso Brasileiro de Engenharia Biomédica**. Uberlândia: Canal 6 Editora. 2014.
41. BEUTEL, J.; KUNDEL, H.L.; METTER R.L.V. **Handbook of Medical Imaging**. Vol. 1. Bellingham, SPIE Press. 2000.
42. INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 12054 - Health informatics -- Digital imaging and communication in medicine (DICOM) including workflow and data management**. Geneva, 2006.
43. NEMA. **DICOM Homepage**. Disponível em: <<http://dicom.nema.org/>>. Acesso em: 28 jan. 2015.
44. AZEVEDO-MARQUES, P. M; SALOMÃO, S.C. PACS: Sistemas de Arquivamento e Distribuição de Imagens. **Revista Brasileira de Física Médica**, Florianópolis, v.3, n.1, 2009.
45. **DICOM Lookup**. Disponível em: <<http://www.dicomlookup.com/default.htm>>. Acesso em: 28 jan. 2015.
46. **DICOM in MeVisLab**. Disponível em: <<http://www.mevislab.de/docs/2.6/FMEwork/ReleaseMeVis/Documentation/Publish/Overviews/DICOMInMeVisLab.html>>. Acesso em: 28 jan. 2015
47. **AULA DE ANATOMIA**. Disponível em: <www.auladeanatomia.com>. Acesso em 28 jan. 2015.
48. TERRIER, F.; GROSSHOLZ, M.; BECKER, C. D, **Spiral CT of the Abdomen**. Vol. 1. Berlin, Springer-Verlag Berlin Heidelberg. 2000.
49. BARON, R. **Liver - Masses I - Characterization**. Disponível em: <<http://www.radiolog.yassistant.nl/en/p446f010d8f420/liver-masses-i-characterization.html>>. Acesso em 28 jan. 2015.
50. RUSS, J.C., **The image processing handbook**. 5th ed. London, CRC/Taylor and Francis. 2007.
51. ANDREANI, B.N., **Utilização do Filtro de Wiener para Melhorar a Detecção de Microcalcificação em Imagens Mamográficas**. 2010. 69f. Tese (Trabalho de Conclusão de Curso em Engenharia Elétrica) - Escola de Engenharia de São Carlos. Universidade de São Paulo, São Carlos. 2010.
52. RANGAYYAN, R.M., **Biomedical image analysis**. Biomedical engineering series. London, CRC Press. 2005.
53. PRATT, W.K., **Digital image processing**. 4th ed., Hoboken. Wiley-Interscience. 2007.
54. RUEDA, L.; MERY, D.; KITTLER, J. **Progress in Pattern Recognition Image Analysis and Applications**. Berlin. Springer. 2007.
55. WIKIA. **Image Watershed-figura11.gif**. Disponível em: <<http://students.wikia.com/wiki/File:Watershed-figura11.gif>>. Acesso em 28 jan. 2015.

56. KLAVA, B., **Segmentação Interativa de Imagens via Transformação Watershed**. 2009. 83f. Teses (Mestrado em Ciências) - Instituto de Matemática e Estatística, Universidade de São Paulo. São Paulo. 2009.
57. ROERDINK, J. B. T. M.; MEIJSTER, A. The Watershed Transform: Definitions, Algorithms and Parallelization Strategies. **Fundamenta Informaticae**. Amsterdam. v.41, n.1, 2001.
58. TOSHIBA, **Manual do Usuário, in Tomógrafo Computadorizado - Aquilion 64 TSX-101 A/E**. Toshiba Corporation.
59. ABRÀMOFF, M. D.; MAGALHÃES, P. J. Image Processing with ImageJ. **Biophotonics International**, Pittsfield, v.11, n.7, 2004.
60. **RGU: CT Windowing**. Disponível em: <<https://www4.rgu.ac.uk/health/radiography/page.cfm?pge=11049>>. Acesso em 28 jan. 2015.
61. BERBER, E. et al., Use of CT Hounsfield unit density to identify ablated tumor after laparoscopic radiofrequency ablation of hepatic tumors. **Surg Endosc**, New York, v.14, n.9, 2000.
62. WOLFRAN. **Dilation - Wolfram Language Documentation**. Disponível em: <<http://reference.wolfram.com/language/ref/Dilation.html>>. Acesso em 28 jan. 2015.
63. DODGE, Y., **The concise encyclopedia of statistics**. 1st. ed. New York, Springer. 2008.