



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
ENGENHARIA BIOMÉDICA
TRABALHO DE CONCLUSÃO DE CURSO

GABRIEL HENRIQUE DE OLIVEIRA LEITE

COMPARAÇÃO DE TÉCNICAS 2D E 3D PARA
SEGMENTAÇÃO DE FÍGADO EM TOMOGRAFIA
COMPUTADORIZADA

UBERLÂNDIA
2017

GABRIEL HENRIQUE DE OLIVEIRA LEITE

COMPARAÇÃO DE TÉCNICAS 2D E 3D PARA SEGMENTAÇÃO DE FÍGADO EM TOMOGRAFIA COMPUTADORIZADA

Parte manuscrita do Projeto de Graduação do aluno Gabriel Henrique de Oliveira Leite, apresentado à Faculdade de Engenharia Elétrica da Universidade Federal de Uberlândia, como requisito parcial para obtenção do grau de Engenheiro Biomédico.

Orientador: Prof.^a Dr.^a Ana Claudia Patrocínio

Assinatura do Orientador

Coordenador: Prof. Dr. Adriano Oliveira Andrade

Assinatura do Coordenador

UBERLÂNDIA
2017

Dedico este trabalho aos meus pais, pelo incentivo, apoio e investimento durante todos os anos da minha graduação.

AGRADECIMENTOS

Agradeço aos meus pais pela oportunidade que me foi dada de cursar Engenharia Biomédica na Universidade Federal de Uberlândia, uma grande oportunidade de melhoria de vida devida a situação econômica e social do meu país.

Ao aluno de Doutorado Ricardo Lima Thomaz pelos ensinamentos, auxílio e incentivo.

À minha orientadora Profa. Dra. Ana Cláudia Patrocínio que me guiou e me ensinou a fazer pesquisa durante todo o processo.

A todos meus professores que de forma direta ou indireta contribuíram para minha formação, como indivíduo e profissional.

Enfim, agradeço a todos as pessoas envolvidas que opinaram, me ajudaram e contribuíram de alguma forma para o meu trabalho.

RESUMO

Devido à elevada taxa de mortalidade decorrente de doenças do fígado e a complexidade no tratamento das informações em exames de Tomografia Computadorizada, fundamentais para a detecção e diagnóstico precoce do câncer de fígado, torna-se aparente a necessidade de sistemas CAD (Computer-Aided Diagnosis) como uma segunda opinião no diagnóstico. Uma das principais etapas nos sistemas CAD é a segmentação do objeto de interesse. Assim, muitos pesquisadores têm proposto novas técnicas de segmentação de fígado. Neste trabalho, avaliamos quantitativamente o desempenho de duas técnicas apresentadas na literatura, uma bidimensional e outra tridimensional, com o objetivo de comparar o desempenho de acordo com cada aspecto metodológico. A primeira técnica avaliada faz o pré-processamento das imagens para redução de ruído e realce de contraste, seguido de um lançamento de sementes determinístico, e crescimento de região bidimensional com pós-processamento. Por outro lado, a segunda técnica não utiliza de qualquer pré ou pós-processamento, realizando o lançamento de sementes de modo não-determinístico e o crescimento de região tridimensional por meio da resposta de um classificador de uma-classe. Em nossa avaliação, a primeira técnica obteve um desempenho de 95,13% enquanto a segunda técnica de 67,54%. Desta forma, considerando a Taxa de Acerto em porcentagem e o Erro Quadrático Médio em cm^3 , podemos concluir que a primeira técnica teve um melhor desempenho em relação a segunda técnica.

Palavras-chave: volumetria hepática, segmentação de fígado, segmentação automática, tomografia computadorizada.

ABSTRACT

Due to the high mortality rate from liver diseases and the complexity in treatment of information in CT scans, required for the early detection and diagnosis of liver cancer, it becomes apparent the need for CAD (Computer-Aided Diagnosis) systems as a second opinion in diagnosis. The segmentation of an object of interest is an important task in CAD systems. Thus, many researchers have proposed new techniques for liver segmentation. In this work, we objectively evaluate the performance of 2D and 3D techniques presented in the literature with the goal of comparing their performances according to methodological aspects. The first technique evaluated preprocesses images for noise reduction and contrast enhancement, followed by a deterministic seed launch, and two-dimensional region growing with post-processing. On the other hand, the second technique does not use any pre- or post-processing, performing the seed launch in a non-deterministic approach and a three-dimensional region growing through the response of a one-class classifier. In our evaluation, the first technique obtained a performance of 94.14% while the second technique was 67.54%. Thus, considering the Hit Rate in percentage and the Mean Square Error in cm^3 , we can conclude that the first technique had a better performance in comparison to the second technique.

Keywords: liver volume, liver segmentation, automatic segmentation, computed tomography.

LISTA DE FIGURAS

Figura 1 - Relação geométrica do exame de TC	11
Figura 2- Resultados do trabalho de (RUSKO et al, 2007).....	16
Figura 3 - Resultados do artigo de (CHEN et al, 2009)	17
Figura 4 - Pontos de localização da costela na imagem de fatia de TC	19
Figura 5 - Fatia original a esquerda e recorte de forma retangular a direita	20
Figura 6 - Fatia do exame de TC com sua respectiva Área de Lançamento de Semente em Região Elíptica (ALSRE)	21
Figura 7 - Exemplo do resultado da técnica de LSRC	21
Figura 8 - Diagrama de blocos da técnica de segmentação tridimensional	24
Figura 9 - Lançamento de semente do software da técnica tridimensional	25
Figura 10 - Diagrama de blocos da avaliação do desempenho das técnicas	28
Figura 11 - Fatias resultantes da técnica de segmentação bidimensional.....	32
Figura 12 - Fatias resultantes da técnica de segmentação tridimensional	33

LISTA DE TABELAS

Tabela 1 - Resultados do trabalho de (LIM; JEONG; HO, 2006)	15
Tabela 2 - Teste do parâmetro de equilíbrio (v) (em inglês, Tradeoff).....	24
Tabela 3 - Resultados da técnica de (ANASTÁCIO, 2015)	29
Tabela 4 - Resultados da técnica de (THOMAZ, 2017)	30
Tabela 5 - Taxa de acerto da técnica de segmentação bidimensional	31
Tabela 6 - Taxa de acerto da técnica de segmentação tridimensional	31

LISTA DE ABREVIATURAS E SIGLAS

2D	Bidimensional
3D	Tridimensional
CAD	Computer-Aided Diagnosis
DM	Desvio Médio
EQM	Erro Quadrático Médio
EUA	Estados Unidos da América
HU	Hounsfield Unit
LSRC	Lançamento de Semente em Região Circular
LSRE	Lançamento de Semente em Região Elíptica
LSRR	Lançamento de Semente em Região Retangular
MELD	Model for End-Stage Liver Disease
RM	Ressonância Magnética
ROI	Region Of Interest
TC	Tomografia Computadorizada
UFU	Universidade Federal de Uberlândia
VA	Volume Automático
VM	Volume Manual

SUMÁRIO

1	INTRODUÇÃO.....	10
2	ESTADO DA ARTE	14
3	MATERIAIS E MÉTODOS.....	18
	3.1 Exames de tomografia computadorizada	18
	3.2 Segmentação por crescimento de região.....	18
	3.3 Técnica de Segmentação Bidimensional	19
	3.3.1 Pré-processamento da imagem.....	19
	3.3.2 Lançamento de Semente em Região Retangular, Elíptica e Circular (LSRR, LSRE e LSRC).....	20
	3.3.3 Conclusão da Técnica de Segmentação Bidimensional	22
	3.4 Técnica de Segmentação Tridimensional	22
	3.4.1 Técnica de Lançamento de Semente utilizando Evolução Diferencial.....	22
	3.4.2 Classificador de uma-classe	23
	3.5 Avaliação do desempenho das técnicas	25
4	RESULTADOS E DISCUSSÃO.....	29
5	CONCLUSÃO	35
6	REFERÊNCIAS BIBLIOGRÁFICAS	36

1 INTRODUÇÃO

O fígado é um órgão de grande importância na manutenção da circulação sanguínea, possui formato de prisma e é um dos maiores órgãos do corpo humano representando cerca de 2% do peso corporal. Suas principais funções no organismo são: metabolismo da glicose, metabolismo proteico, armazenamento de vitamina e ferro, metabolismo medicamentoso, formação de bile e coagulação sanguínea. Além disso, o volume sanguíneo de um fígado saudável é de aproximadamente 450 mililitros (GUYTON; HALL, 2006).

As doenças que mais atacam o fígado são: cirrose hepática, hepatite viral, icterícia, hipertensão porta e ascite, deficiências nutricionais e encefalopatia hepática. Dentre elas, a cirrose hepática é a que tem a maior incidência na população brasileira (MINISTÉRIO DA SAÚDE, 2017; GUYTON; HALL, 2006). Tanto a cirrose hepática quanto a hepatite viral podem evoluir, direta ou indiretamente, para um câncer de fígado (YANG et al., 1997).

Segundo o Ministério da Saúde, as doenças crônicas do fígado, incluindo o câncer de fígado e a cirrose, são as doenças que mais atacam a população brasileira. Elas foram causa de 18,7% das mortes no Brasil em 2013 entre pessoas do sexo masculino de 20 a 59 anos (MONTEIRO et al., 2015). Nos Estados Unidos da América (EUA) essa porcentagem foi de 16,79% no ano de 2014, incluindo pessoas de todas as faixas etárias (IHME, 2014).


Nos pacientes em estágio terminal do câncer de fígado, é necessária uma cirurgia de transplante de fígado, sendo esse um dos motivos para a alta taxa de mortalidade no Brasil, uma vez que há falta de infraestrutura para atender os pacientes que necessitam do transplante de fígado. Mesmo com a medida do Ministério da Saúde na aplicação da escala MELD (Model for End-Stage Liver Disease) (TEIXEIRA et al., 2006), em 2015, foram realizados apenas 1.809 transplantes de fígado, enquanto a necessidade estimada para o transplante foi de 5.069, deixando 78,5% desse total sem o transplante (MEDINA PESTANA et al., 2016).

Para garantir a sobrevivência dos portadores do câncer de fígado, ou seja, evitar que um paciente chegue a um estágio terminal do câncer de fígado, necessite de um transplante ou venha a óbito, é necessária a detecção precoce do câncer, pois se detectado nos estágios iniciais a chance de sobrevivência em 5 anos é de 31%. Por

outro lado, a sobrevida em 5 anos para a detecção nos estágios finais do câncer é de apenas 3% (AMERICAN CANCER SOCIETY, 2016). Dentre as diversas modalidades de imagiologia médica, um dos padrões ouro para a detecção precoce é realizado com o exame de Tomografia Computadorizada (TC). A TC tem o nível de acerto entre 75% a 90% em detectar lesões no fígado, possibilitando tratamentos mais eficazes, como a remoção cirúrgica de um possível câncer (INSTITUTO NACIONAL DO CÂNCER, 1998).

A TC é um equipamento médico-hospitalar que foi criado em 1969 por Godfrey Hounsfield e sua equipe. O exame de TC auxilia o diagnóstico e é baseado na emissão de raios X. A imagem tomográfica é formada no plano transversal por meio da atenuação de feixes de raios X que atravessam o objeto analisado. A captação desses feixes é feita por detectores de raios X diametralmente opostos à um tubo de raios X que contorna o corpo do paciente (no eixo longitudinal), podendo ser de forma espiral como para o exame de TC helicoidal. Na Figura 1 podemos ver os eixos do exame, sendo o eixo Z o eixo longitudinal (onde o paciente é posicionado) e o plano XY a perspectiva na qual a imagem será formada (NOO et al., 2009).

Figura 1 - Relação geométrica do exame de TC



Fonte: (NOO et al., 2009)

O detector da TC recebe diferentes quantidades de energia (fótons de raios X) dependendo do material atravessado pelos raios X. Logo, a intensidade dos raios X que chega ao detector em cada ângulo é convertida em sinal digital. Esses valores são utilizados para gerar a matriz da imagem, onde cada ponto se refere a uma densidade diferente de uma parte específica do corpo (SANTA BÁRBARA, 2006).

Essa matriz é convertida na escala de Hounsfield, nela cada meio é padronizado por um valor na Unidade de Hounsfield (do inglês Hounsfield Unit ou HU).

Embora as imagens resultantes dos exames de TC forneçam detalhes importantes para os radiologistas, o grande volume de informação pode dificultar o diagnóstico no momento de interpretar as imagens num curto período de tempo. Para auxiliar os profissionais na avaliação, pode ser utilizado, além das imagens originadas da TC, um sistema de Diagnóstico Auxiliado por Computador, do inglês CAD (Computer-Aided Diagnosis) (TAJIMA et al., 2007).

Segundo o trabalho de Azevedo-Marques (2001), o sistema CAD tem como objetivo auxiliar o diagnóstico realizado pelo especialista por meio do resultado de análises quantitativas de imagens radiográficas, podendo ser utilizados como uma segunda opinião na tomada de decisão do diagnóstico (AZEVEDO-MARQUES, 2001). Com essa segunda opinião espera-se ter uma melhora na acurácia do diagnóstico. Além disso, o CAD tem o objetivo de extrair e quantificar atributos de uma imagem em formato digital; com o processamento de imagem para realce, segmentação e extração de atributos ou com a inclusão de métodos para seleção de atributos, estatística e reconhecimento de padrões (AZEVEDO-MARQUES, 2001).

A segmentação em sistemas CAD é uma área muito explorada na literatura, pois isolando a região de interesse ela auxilia no diagnóstico ou fornece informações quantitativas adicionais ao especialista. Como no trabalho dos autores Atkins e Mackiewicz (1998), vemos o uso da segmentação nas imagens de RM (Ressonância Magnética) para o diagnóstico de tumores cerebrais, esclerose múltipla e Alzheimer (ATKINS; MACKIEWICH, 1998). Os autores expuseram diversos algoritmos para segmentação em imagens médicas, além de proporem um método próprio de segmentação. Devido a abrangência e grande utilização de diversos métodos de segmentação na literatura, acredita-se na necessidade da análise quantitativa dos métodos e algoritmos de segmentação a fim de determinar a melhor forma possível de se fazer uma segmentação.

A segmentação correta do fígado tem um papel fundamental para os sistemas CAD na prática clínica, como na detecção de disfunções, patologias, estudos anatômicos e pré-operativos (HUANG et al., 2016).

O objetivo deste trabalho é comparar o desempenho de técnicas de segmentação de fígado 2D e 3D a partir do algoritmo de crescimento de região em imagens de tomografia computadorizada.

2 ESTADO DA ARTE

Nesta seção serão apresentados trabalhos de grande relevância para a área de segmentação de fígado em exames de Tomografia Computadorizada, de modo a expor o estado-da-arte para avaliar técnicas e resultados já existentes na literatura.

Diante das muitas técnicas de segmentação de imagem, o artigo de Lim et al. (2006) propôs uma segmentação automática baseada em região e contorno, com o objetivo de solucionar o problema do tempo gasto na segmentação tradicional em 2D, considerando as características de um exame abdominal de TC. Desta forma, eles extraíram características morfológicas e de intensidade de pixel, como a forma, localização e os tons de cinza do fígado.

Nesse trabalho os autores utilizaram três etapas para a segmentação do fígado. A primeira etapa foi um tratamento da imagem, retirando a parte inferior direita das fatias, onde é improvável o fígado estar localizado, a segunda etapa foi buscar uma detecção de alcance com um contorno inicial do fígado usando filtro morfológico, e a última etapa foi a segmentação do fígado baseado em contornos. Posteriormente os autores compararam os resultados automáticos com o volume de segmentações manuais utilizados como padrão ouro.

Eles concluíram que os testes feitos pela segmentação baseada em região e contorno com filtro morfológico tiveram um ótimo resultado. Como mostrado na Tabela 1, o erro de segmentação do volume automático com o volume manual chega a, no máximo, 3%. Essa técnica teve uma eficiência muito alta e o artigo cita também uma velocidade de processamento 20 a 60 segundos por fatia.

Tabela 1 - Resultados do trabalho de (LIM; JEONG; HO, 2006)

Exames	Volume Automático (mm ³)	Volume Manual (mm ³)	Erro(%)
1	3470,03	3531,83	1,750
2	3910,11	4002,98	2,320
3	5490,59	5543,22	0,950
4	9141,62	8942,69	-2,240
5	12817,14	12394,59	-3,409
6	13762,82	13836,11	-0,530
7	13611,91	13699,13	0,637
8	13291,01	13119,94	-1,304
9	12877,2	1299173	0,882
10	9951,23	10314,36	3,521
11	7812,37	7897,15	1,074
12	6395,71	6169,17	-3,672
13	5519,07	5341,12	-3,332
14	4710,87	4891,89	3,703
15	4132,7	4197,11	1,535
16	3727,95	3781,98	1,429
17	3499,25	3544,57	1,279
18	3073,89	3101,93	0,904
19	2618,92	2631,32	0,471

Fonte: (LIM; JEONG; HO, 2006)


Como a segmentação manual de fígado consome muito tempo, o trabalho de Ruskó et al (2007), teve como objetivo criar uma segmentação completamente automática rápida e precisa.

Para isso, eles utilizaram a técnica de crescimento de região que funciona a partir do agrupamento de pixels com características em comum (CONCI, 2016). A metodologia consistiu em alguns passos, o primeiro deles foi determinar uma região para o lançamento de semente contendo pixels localizados dentro do fígado, o segundo passo foi separar o fígado do coração para evitar erros na técnica de segmentação, segundo o autor, o fígado e o coração possuem tonalidades de cinza muito próximas. Logo depois, eles aplicaram um método de crescimento de região a partir de uma semente já determinada no primeiro passo. Já o último passo foi aplicar um pós-processamento para corrigir erros de segmentação muito fora do padrão, seja para as imagens que tiveram muita segmentação ou pouca segmentação.

Os exames foram separados em casos fáceis, intermediários ou difíceis. Conforme a Figura 2, eles demonstraram os resultados para cada caso, obtendo um

bom aproveitamento nos casos fáceis e intermediários, porém resultados não tão favoráveis nos casos difíceis (com grandes lesões). Na Figura 2 foi apresentado, da esquerda para direita, as fatias sagital, coronal e transversal, sendo de cima para baixo os exames de caso fácil, intermediário e difícil.

Figura 2- Segmentação manual em vermelho e segmentação feita pelo trabalho de (RUSKO et al, 2007) em azul



Fonte: (RUSKO; BEKES, 2007)


Eles explicaram no trabalho que o método apresentado não detectou grandes lesões ou lesões muito mais escuras que o fígado (RUSKO; BEKES, 2007). Ainda assim os exames segmentados automaticamente tiveram um melhor resultado comparado com as segmentações manuais.

Já o trabalho de Chen et al. (2009) teve como objetivo fazer uma segmentação automática mais precisa do fígado, usando uma técnica de segmentação de fígado a partir de um crescimento de região combinado com pré-processamento e pós-processamento. No pré-processamento foi utilizado um filtro anisotrópico para

melhorar a definição morfológica da imagem e preservar os limites do objeto e os detalhes finos para se adequar a segmentação do fígado.

Após essa etapa foi aplicado um algoritmo de crescimento de região por fatia, levando em conta o ponto de centroide da região do fígado. Como esse ponto de centroide sofre pequenas mudanças no processo de segmentação, ele foi utilizado para guiar as próximas fatias, ou seja, as últimas fatias tiveram uma melhor estimativa de onde estava o fígado com relação as fatias anteriores. Por último, veio a etapa de pós-processamento, que se baseou no preenchimento de buracos na imagem e remoção de fragmentos que não pertenciam ao fígado. Os resultados foram expressos na Figura 3 abaixo. Os autores concluíram, com os exemplos anteriores e alguns testes, que o método teve uma boa eficiência (CHEN et al., 2009).

Figura 3 – Exemplos de fatias segmentadas pelo trabalho de (CHEN et al, 2009)



Fonte: (CHEN et al., 2009)

3 MATERIAIS E MÉTODOS

3.1 Exames de tomografia computadorizada

Neste trabalho, a fim de uniformizar e padronizar os resultados das técnicas de segmentação investigadas, foram selecionados apenas os exames de TC utilizados por Anastácio et al. (2015) que também estavam disponíveis no banco de imagens do trabalho de Thomaz et al. (2017). Desta forma, foram utilizados 10 exames anonimizados de TC abdominal de 10 pacientes. Tais exames já estavam segmentados manualmente e seus volumes manuais foram utilizados como padrão ouro na comparação das técnicas. Em média, cada exame possui 265 fatias podendo ou não possuir múltiplas fases de contraste. Assim, este trabalho avalia um total de 2650 fatias de tomografia computadorizada.

Conforme descrito anteriormente, para a execução do trabalho foram utilizadas duas técnicas de segmentação de fígado em imagens de TC. A técnica proposta por Anastácio et al. (2015) já possui resultados divulgados em relação aos exames analisados, portanto, neste trabalho, apenas foi descrita a metodologia da técnica de segmentação de fígado utilizada por Anastácio, 2015. Por outro lado, a segunda técnica, proposta por Thomaz et al. (2017), foi testada para gerar os resultados necessários para comparação quantitativa das duas técnicas de segmentação propostas neste trabalho.

3.2 Segmentação por crescimento de região


Ambas as técnicas avaliadas neste trabalho se basearam no conceito do algoritmo de crescimento de região, do inglês Region Growing. A técnica de crescimento de região funciona a partir do agrupamento de pixels com características em comum. Na segmentação, isto ocorre quando é escolhido um pixel ou conjuntos de pixel (denominados sementes) que vão agrupar pixels adjacentes com características semelhantes como, no caso das imagens médicas, tons de cinza (CONCI, 2016).

Apesar de ser uma boa técnica de segmentação, é preciso tomar cuidado com a representatividade das sementes que irão dar origem ao crescimento de região, pois elas precisam abranger adequadamente o objeto de interesse na segmentação.

3.3 Técnica de Segmentação Bidimensional

A técnica de segmentação bidimensional de Anastácio et al. (2015) utiliza um lançamento de semente de forma automática. Antes de implementar o algoritmo eles trabalharam em identificar e utilizar a região interna das costelas, onde se encontra o fígado. Após o processo de limiarização dos limites dos ossos em quatro direções (VbE - Vertical, borda esquerda para o centro; VbD - Vertical, borda direita para o centro; HbS – Horizontal, borda superior para o centro e HbI - Horizontal, borda inferior para o centro), eles encontraram os pontos na matriz das fatias de TC. Como mostra a Figura 4 (ANASTÁCIO, 2015).

Figura 4 – Pontos de localização da costela na imagem de fatia de TC



Fonte: (ANASTÁCIO, 2015)

Após encontrar a região interna das costelas, eles determinaram que fosse utilizado a região esquerda da imagem para o lançamento de semente, já que a maior parte do fígado está do lado esquerdo, e isso pouparia recursos computacionais e possíveis erros no lançamento de semente.

3.3.1 Pré-processamento da imagem

Antes de explicar sobre as técnicas de lançamento de semente o autor cita os possíveis pré-processamentos para imagens. Com o objetivo de melhorar o contraste entre o fígado e os tecidos adjacentes, o autor testa todos, um a um. Isso inclui os filtros de média aritmética, mediana, média geométrica, wiener, laplaciano e operador Sobel, com cada filtro eles testaram as transformações logarítmica, exponencial e gama. Em seguida eles concluíram que a melhor combinação no pré-processamento

é o filtro de Wiener com Transformação Gama que será utilizado nesse trabalho para comparação.

3.3.2 Lançamento de Semente em Região Retangular, Elíptica e Circular (LSRR, LSRE e LSRC)

Determinado a região interna das costelas, os autores testaram três tipos de lançamento de semente em regiões distintas, o primeiro lançamento a ser testado foi em região retangular (LSRR) que liga os quatro pontos da região interna da costela (citados no subtópico anterior) e forma-se um retângulo conforme Figura 5. Dentro deste retângulo é feito uma busca dos pixels que satisfazem o valor de intensidade do fígado calculando o centro de massa. Com isso, o centro de massa será considerado o ponto de lançamento da semente.


Figura 5 - Fatia original a esquerda e recorte de forma retangular a direita



Fonte: (ANASTÁCIO, 2015)

No Lançamento de Semente em Região Elíptica (LSRE) é feito uma equação com os quatro pontos da região interna da costela para que eles formem uma elipse, com essa elipse exclui-se algumas partes da costela ou partes do músculo e melhora-se o lançamento de semente em relação ao LSRR conforme mostrado na Figura 6.

Figura 6 - Fatia do exame de TC com sua respectiva Área de Lançamento de Semente em Região Elíptica (ALSRE)




Fonte: (ANASTÁCIO, 2015)

Os autores fazem o mesmo processo de calcular o centro de massa da figura elíptica (assim como eles calcularam na retangular) utilizando-o para o lançamento de semente.

Com o mesmo objetivo de tentar melhorar o LSRR foi utilizado o Lançamento de Semente em Região Circular (LSRC) que seguiu processos parecidos com os lançamentos anteriores, porém foi utilizado o conceito de dilatações morfológicas em formato circular. No LSRC foi utilizado três dilatações, a primeira para excluir ossos da coluna e os rins, a segunda para remoção das costelas e a última dilatação para remover estruturas centrais da fatia. O resultado da técnica está exposto na Figura 7.

Figura 7 – Exemplo do resultado da técnica LSRC após o tratamento com as três dilatações morfológicas



Fonte: (ANASTÁCIO, 2015)

Do mesmo modo das técnicas anteriores, foi calculado o centro de massa para ser utilizado no lançamento de semente. De todos os lançamentos testados, os autores concluíram que o melhor lançamento é o de região circular (LSRC) (ANASTÁCIO, 2015).

3.3.3 Conclusão da Técnica de Segmentação Bidimensional

Em suma, a técnica de segmentação bidimensional utilizou segmentações manuais como padrão ouro e comparou com os demais pré-processamentos e técnicas de lançamento de semente. O melhor resultado obtido foi com o filtro Wiener mais Transformação Gama no LSRC (Lançamento de Semente em Região Circular) com o acerto de 94,14% (ANASTÁCIO et al., 2016).

3.4 Técnica de Segmentação Tridimensional

Uma técnica de segmentação tridimensional baseada no crescimento de região difere de técnicas bidimensionais quanto à avaliação de pixels em fatias adjacentes. Ainda assim, o crescimento de região tridimensional pode utilizar os mesmos métodos empregados em técnicas bidimensionais. Entretanto, uma vez que a segmentação tridimensional por crescimento de região pode resultar em maior número de erros de extravasamento, foi feita uma investigação em um trabalho que utiliza um lançamento de semente baseado em evolução diferencial e um crescimento de região baseado em classificadores de uma-classe (THOMAZ et al., 2016, 2017).

3.4.1 Técnica de Lançamento de Semente utilizando Evolução Diferencial

Na técnica de segmentação tridimensional investigada neste trabalho, os autores utilizaram um lançamento de semente baseado em Evolução Diferencial (ED) para definir um algoritmo não-determinístico e aprimorar a técnica de lançamento de semente. Com este objetivo, foi utilizada uma função de aptidão com base na intensidade, contraste, morfologia e características de localização do fígado (THOMAZ et al., 2015).

3.4.2 Classificador de uma-classe

Além da técnica de lançamento de sementes não-determinística, o trabalho investigado expande o critério de seleção e crescimento utilizado nos algoritmos de crescimento de região.

Desta forma, os autores propuseram o uso de classificadores de uma-classe para modelar o parênquima hepático. No trabalho de Thomaz et al. (2017) foi implementado uma Máquina de Vetores de Suporte (SVM, do inglês Support Vector Machines) para ser usado como classificador de uma-classe. Para discriminar diferentes intervalos de segmentação, os autores treinaram três SVMs distintas, por meio da variação da quantidade de dados de treinamento utilizados, para obter três níveis de confiança: 85%, 95% e 100% resultando em um alto, médio e baixo nível de confiança em relação aos pixels adjacentes no crescimento de região (THOMAZ et al., 2017). Além disso, os autores definiram outros três modelos baseados nesta metodologia variando o parâmetro de equilíbrio (ν) dos SVMs. Este parâmetro define a quantidade de exemplos utilizados como base para definição da fronteira de decisão do classificador. Um menor valor de parâmetro determina uma menor quantidade de vetores de suporte e, portanto, uma fronteira de decisão mais suave. Por outro lado, um parâmetro maior resulta exatamente no oposto: maior quantidade de vetores de suporte e, assim, uma fronteira mais rígida.

Antes de realizar o treinamento dos SVMs, uma quantidade de sementes (N_S) deve ser definida pelo usuário. Uma vez que o algoritmo de lançamento analisa cada fatia (N_F), são geradas um total de $N_S * N_F$ sementes no exame. Para cada semente é criada uma região de interesse de dimensão 7x7 ao redor da semente para extrair os atributos, que são: a média da intensidade e a média e o desvio padrão do contraste (THOMAZ et al., 2017). Com esses atributos são treinados os três SVMs.

A partir desses classificadores é feito o crescimento de região, que utiliza os vizinhos (26-concetado) de cada semente. Para cada vizinho, o classificador analisa a ROI (Região de Interesse, do inglês Region Of Interest) por meio de três modelos, separando-os em um alto, médio e baixo nível de confiança, como dito anteriormente. Os pixels são classificados por cores, um alto nível de confiança é definido pela cor verde, médio nível de confiança pela cor amarela e baixo nível de confiança pela cor vermelha. Se o pixel satisfizer um dos classificadores ele é inserido na matriz de pixels resultantes da segmentação, caso contrário ele é excluído e outro pixel é

analisado, com isso, o software gera como resultado três matrizes distintas para cada nível de confiança.

O parâmetro de equilíbrio utilizado nos classificadores é de 0.35, pois, em um estudo de caso, o trabalho de (THOMAZ et al., 2017) apresentou uma boa segmentação tridimensional utilizando um parâmetro de equilíbrio de 0.35 conforme a Tabela 2. Estes resultados motivaram a utilização desta metodologia para comparação quantitativa com os trabalhos do primeiro autor.


Tabela 2 - Teste do parâmetro de equilíbrio (v) (em inglês, Tradeoff)

Parâmetro de equilíbrio (v)	Segmentação Correta	Segmentação Incorreta
0,35	87,30%	12,17%
0,50	73,30%	26,70%
0,65	61,70%	38,30%

Fonte: (THOMAZ et al., 2017)

Resumidamente, o processo de segmentação do fígado na técnica de segmentação tridimensional é descrito no diagrama de blocos da Figura 8.


Figura 8 - Diagrama de blocos da técnica de segmentação tridimensional



3.5 Avaliação do desempenho das técnicas

Para o trabalho de Anastácio et al. (2015), os resultados foram disponibilizados pelo autor, dos quais foi possível identificar os exames que estavam de acordo com a base de dados disponível. Já no trabalho de Thomaz et al. (2017), foram feitos os testes com os 10 exames em comum entre os trabalhos. Esses testes foram realizados com o software disponibilizado pelo autor, tendo parâmetros já padronizados, sendo eles: os parâmetros probabilísticos da Evolução Diferencial (Fator de cruzamento = 0,60 e Fator de mutação = 0,01) e o parâmetro de equilíbrio ($v = 0,35$). Entretanto, uma vez que a quantidade de sementes poderia ser modificado pelo usuário, utilizamos um total de 150 sementes durante os testes, como demonstrado na Figura 9 no campo Tamanho da População, do inglês Population Size.

Figura 9 - Lançamento de semente do software da técnica tridimensional



Após a seleção do exame e dos parâmetros, o software gerou como resultado três matrizes de segmentação (uma matriz para cada intervalo de confiança). As matrizes foram salvas na mesma pasta das imagens resultantes da técnica. A partir dessas matrizes, obteve-se os pixels dos exames segmentados como valores binários

(sendo 1 para fígado e 0 para não fígado). Foi feita uma união dessas três matrizes gerando uma única matriz resultante, e foi calculada a soma aritmética da matriz resultante (somando todos os valores iguais a 1) obtendo a quantidade total de pixels segmentados (T_V). Com a quantidade total de pixels, foi calculado o volume do fígado de acordo com a equação (1) abaixo. E para obter o resultado em cm^3 a equação foi dividida por 10^3 .

$$Volume = (T_V * SPF * PS) / 10^3 \quad (1)$$

Onde:

- T_V = Número total de pixels resultante da somatória das matrizes
- SPF = Valor do Spiral Pitch Factor do exame
- PS = Dimensões do pixel em mm

Com os resultados dos trabalhos de (ANASTÁCIO, 2015) e (THOMAZ et al., 2017) foi feita uma comparação do desempenho de cada técnica. Para se fazer essa comparação do desempenho foram utilizados parâmetros semelhantes aos do trabalho de (ANASTÁCIO, 2015), que são: taxa de acerto em porcentagem e Erro Quadrático Médio (EQM) com seu Desvio Médio (DM). Para calcular a taxa de acerto foi utilizado a seguinte equação (2) descrita abaixo.

$$TaxaAcerto = \left(\left(\frac{V_{tM} - V_{tA}}{V_{tM}} \right) * 100 \right) - 100 \quad (2)$$

Onde:

- V_{tM} = Volume total do exame medido manualmente
- V_{tA} = Volume total do exame medido automaticamente

O Erro Quadrático Médio (EQM) foi usado para determinar se o modelo estudado se ajustou bem aos dados, ou seja, o quão próximo o Volume Automático (VA) está em relação ao Volume Manual (VM). Quanto mais próximo de zero for o EQM, menor é a quantidade de erro por fatia. A unidade do erro está na mesma medida dos volumes, em cm^3 . E ele foi calculado de acordo com a equação (3).

$$EQM = \frac{1}{n} \sum_{i=1}^n (Xi - Yi)^2 \quad (3)$$

Onde:

- n = Número total de fatias no exame
- Xi = Volume da fatia i medido da segmentação automática
- Yi = Volume da fatia i medido da segmentação manual

Já o Desvio Médio (DM) foi calculado seguindo a equação (4) abaixo.


$$DM = \sqrt{\frac{\sum_{i=1}^n (Xi - Xm)^2}{n}} \quad (4)$$

Onde:

- n = Número total de fatias no exame
- Xi = Volume da fatia i medido da segmentação automática
- Xm = Média dos valores da fatia daquele exame

A Figura 10 apresenta um diagrama de blocos com a metodologia realizada neste trabalho.

Figura 10 - Diagrama de blocos da avaliação do desempenho das técnicas



4 RESULTADOS E DISCUSSÃO

Conforme metodologia definida, apresentamos primeiramente os resultados de segmentação automática bidimensional de acordo com o trabalho original (ANASTÁCIO, 2015).

A Tabela 3 apresenta os resultados de Anastácio et al. (2015) com as taxas de acerto de cada exame e seus respectivos erros. Na primeira coluna temos o número de cada exame, na segunda coluna os Volumes Manuais (VM), que são os volumes dos fígados calculado automaticamente por meio do software ImageJ após segmentação manual. Na terceira coluna são apresentados os Volumes Automáticos (VA) que são os cálculos de volume feito pela segmentação automática com Filtro de Wiener mais Transformação Gama, na quarta coluna as taxas de acerto e na última coluna o Erro Quadrático Médio (EQM) mais ou menos o Desvio Médio (DM).

Tabela 3 - Resultados da técnica de (ANASTÁCIO, 2015)

Exames	VM (cm ³)	VA (cm ³)	Taxa de Acerto (%)	EQM $\pm$ DM (cm ³)
1	200,74	201,04	99,85	23,41 $\pm$ 2,16
2	1093,81	1072,44	98,05	22,68 $\pm$ 2,32
3	755,64	845,41	88,12	1,88 $\pm$ 0,69
4	728,41	867,11	80,96	3,40 $\pm$ 0,75
5	958,48	1334,00	60,82	19,85 $\pm$ 1,65
6	1484,48	865,63	58,31	32,41 $\pm$ 3,47
7	1489,60	1833,72	76,90	11,92 $\pm$ 1,58
8	1288,87	988,52	76,70	83,34 $\pm$ 3,97
9	837,18	729,10	87,09	11,38 $\pm$ 1,65
10	1468,80	1066,79	72,63	49,20 $\pm$ 3,68
Média Aritmética	1030,60	980,38	79,94	

Fonte: (ANASTÁCIO, 2015)

De acordo com a Tabela 3, foi observado que a melhor taxa de acerto foi do exame 1 com 99,85% e o menor EQM foi do Exame 3 com 1,88 e DM de 0,69. Já os exames 6 e 8 tiveram a pior taxa de acerto e o maior EQM, respectivamente.

Em relação as médias dos volumes de todos os exames, a diferença entre VM (volume manual) e VA (volume automático) foi muito pequena, sendo que VA ficou

menos de 5% menor que VM, ou seja, a média de VA corresponde a aproximadamente 95,13% da média de VM.

A Tabela 4 mostra os resultados da técnica de Thomaz et al. (2017) referente aos exames de 1 a 10. Temos o número dos exames na primeira coluna, o VM na segunda coluna, o VA (volume calculado pela técnica) na terceira coluna, a taxa de acerto em porcentagem na quarta coluna e o EQM com DM na última coluna.

Tabela 4 - Resultados da técnica de (THOMAZ, 2017)

Exames	VM (cm ³)	VA (cm ³)	Taxa de Acerto (%)	EQM $\pm$ DM (cm ³)
1	200,74	121,65	60,60	4,95 $\pm$ 4,49
2	1093,81	660,08	60,35	1,21 $\pm$ 2,1
3	755,61	536,76	71,04	2,92 $\pm$ 2,88
4	728,41	496,80	68,20	4,04 $\pm$ 5,7
5	958,48	526,34	54,91	1,74 $\pm$ 2,16
6	1484,48	901,09	60,70	16,2 $\pm$ 16
7	1489,59	1100,80	73,90	5,91 $\pm$ 7,31
8	1288,87	972,12	75,42	60,77 $\pm$ 315,2
9	837,18	718,01	85,77	1,55 $\pm$ 1,72
10	1468,79	927,09	63,12	17,98 $\pm$ 22,64
Média Aritmética	1030,60	696,07	67,40	

A partir da Tabela 4, foi observado que o exame 9 teve a melhor taxa de acerto com 85,77% e também um dos menores EQMs com 1,55 e DM de 1,72, porém o exame 2 foi o de menor EQM com 1,21 e DM de 2,1. Os piores resultados estão no exame 5 com taxa de acerto de 54,91% (menor que a média calculada) e no exame 8 com EQM de 60,77 e DM de 315,2. Uma outra análise a ser feita é que os EQMs e DMs, com exceção do exame 9, não passaram de 18 e 23, respectivamente.

Em relação as médias dos volumes de todos os exames, VA apresentou uma diferença considerável de VM, cerca de 32% a menos do volume manual. Ou seja, VA foi aproximadamente 67,54% de VM.

Em suma, a Tabela 5 apresenta o melhor pré-processamento utilizado, o melhor lançamento de semente e o resultado final da técnica de Anastácio et al. (2015).

Tabela 5 - Taxa de acerto da técnica de segmentação bidimensional

Filtro de Pré-Processamento	Técnica de Segmentação Aut.	VM (cm³)	VA (cm³)	Acerto (%)
Filtro de Wiener com Transformação Gama	ALSRC	1030,60	980,38	95,13

Fonte: (ANASTÁCIO, 2015)

Para analisar o desempenho da técnica de Thomaz et al. (2017) utilizamos o mesmo cálculo feito na Tabela 5, ou seja, encontrar a taxa de acerto por meio das médias de ambas segmentações (manual e automática). Logo, a Tabela 6 apresenta o resultado final da técnica de segmentação tridimensional com suas respectivas médias e a taxa de acerto.

Tabela 6 - Taxa de acerto da técnica de segmentação tridimensional


Técnica de Segmentação Aut.	VM (cm³)	VA (cm³)	Taxa de Acerto (%)
Técnica Tridimensional	1030,60	696,07	67,54

A partir dos resultados coletados, podemos identificar uma diferença na taxa de acerto de 27,59% entre uma técnica e outra. A Tabela 7 mostra os resultados de ambas as técnicas lado a lado. E para melhor entender os resultados apresentados nas tabelas anteriores, a Figura 11 mostra as fatias resultantes da técnica de segmentação bidimensional de (a) a (i), referente as tabelas 3 e 5.

Tabela 7 - Resultados da técnica de segmentação bidimensional e tridimensional

Exames	Técnica de Segmentação Bidimensional		Técnica de Segmentação Tridimensional	
	Taxa de Acerto (%)	EQM $\pm$ DM (cm³)	Taxa de Acerto (%)	EQM $\pm$ DM (cm³)
1	99,85	23,41 $\pm$ 2,16	60,6	4,95 $\pm$ 4,49
2	98,05	22,68 $\pm$ 2,32	60,35	1,21 $\pm$ 2,1
3	88,12	1,88 $\pm$ 0,69	71,04	2,92 $\pm$ 2,88
4	80,96	3,40 $\pm$ 0,75	68,2	4,04 $\pm$ 5,7
5	60,82	19,85 $\pm$ 1,65	54,91	1,74 $\pm$ 2,16
6	58,31	32,41 $\pm$ 3,47	60,7	16,2 $\pm$ 16
7	76,9	11,92 $\pm$ 1,58	73,9	5,91 $\pm$ 7,31
8	76,7	83,34 $\pm$ 3,97	75,42	60,77 $\pm$ 315,2
9	87,09	11,38 $\pm$ 1,65	85,77	1,55 $\pm$ 1,72
10	72,63	49,20 $\pm$ 3,68	63,12	17,98 $\pm$ 22,64

Figura 11 - Fatias resultantes da técnica de segmentação bidimensional




Fonte: (ANASTÁCIO, 2015)

Nesses resultados foi observado um excesso de segmentação entre os lobos direito e esquerdo do fígado nas imagens (d) e (e). E em algumas outras fatias como na (h) se vê pontos não segmentados na borda do fígado. Apesar dos detalhes, a maior parte do fígado foi segmentado corretamente.

Já na Figura 12 se tem uma sequência de fatias resultantes do exame 7 da técnica de segmentação tridimensional de (a) a (i), referentes as tabelas 4 e 6.

Figura 12 - Fatias resultantes da técnica de segmentação tridimensional



A técnica de segmentação tridimensional normalmente não ultrapassa os limites do fígado, porém deixa de segmentar alguns vasos sanguíneos e lesões do fígado como em (e) e (f). Nas fatias bem segmentadas (a) e (b) vemos uma porção maior de pontos verdes (alto nível de confiança), mostrando um melhor desempenho da técnica, porém, nas fatias menos segmentadas (e), (f) e (h), existem muitos pontos vermelhos (baixo nível de confiança) deixando de preencher boa parte do fígado devido a metodologia empregada pelo autor, que interrompe o crescimento de região quando o pixel é classificado com baixo nível de confiança, o que explica a porcentagem de 67,54% da Tabela 6.

Apesar da taxa de acerto de 67,54%, a técnica de segmentação tridimensional apresenta um EQM menor em relação a outra técnica analisada em 8 dos 10 exames estudados, mostrando que a técnica tem um bom resultado se analisada fatia a fatia. Além disso, ela consegue diferenciar bem os dois lobos do fígado na segmentação e

também não ultrapassa os limites do fígado. Já a técnica de segmentação bidimensional abrange melhor o fígado, e em alguns exames específicos como os exames 1 e 2 a taxa de acerto supera o resultado final.

5 CONCLUSÃO

A fim de comparar quantitativamente o desempenho de duas técnicas de segmentação de fígado apresentadas na literatura, analisando seus aspectos metodológico por meio da Taxa de Acerto em porcentagem e do EQM em cm^3 , foi observado um melhor desempenho da técnica de segmentação bidimensional com 95,13% e um desempenho de 67,54% para a técnica de segmentação tridimensional.

As principais diferenças entre as duas técnicas analisadas foram: o não acréscimo de filtros no pré-processamento e a não utilização de pós-processamento na técnica de segmentação tridimensional. Acredita-se que técnicas geométricas de preenchimento de buraco (do inglês hole-filling) que preenchessem os vasos sanguíneos e lesões não segmentadas, melhoraria o desempenho dessa técnica.

Considerando a grande variância dos EQMs nas técnicas avaliadas, a análise de outros parâmetros estatísticos traria mais informações relevantes na avaliação de cada técnica. Para trabalhos futuros, o cálculo da taxa de acerto fatia a fatia seria um bom parâmetro a ser avaliado uma vez que o EQM é influenciado por valores extremos e a visualização do acerto de cada fatia exporia melhor os resultados.

6 REFERÊNCIAS BIBLIOGRÁFICAS

AMERICAN CANCER SOCIETY. Liver Cancer Early Detection, Diagnosis and Staging, 2016. Disponível em: <<https://www.cancer.org/cancer/liver-cancer/detection-diagnosis-staging.html>>

ANASTÁCIO, R. Segmentação e volumetria automática de fígado a partir de imagens tomográficas. [s.l.] UFU, 2015.

ANASTÁCIO, R. et al. Comparação Entre Técnicas Para Segmentação Automática De Fígado Utilizando Crescimento De Região. Revista Brasileira de Inovação Tecnológica em Saúde ISSN: 2236-1103, v. 5, n. 4, p. 1–12, 2016.

ATKINS, M. S.; MACKIEWICH, B. T. Fully automatic segmentation of the brain in MRI. IEEE Transactions on Medical Imaging, v. 17, n. 1, p. 98–107, 1998.

AZEVEDO-MARQUES, P. M. DE. Diagnóstico auxiliado por computador na radiologia. Radiologia Brasileira, v. 34, n. 5, p. 285–293, 2001.

BRASIL. Fígado, 2017. Disponível em: <<http://portalsaude.saude.gov.br/index.php/o-ministerio/principal/secretarias/366-sas-raiz/dahu-raiz/transplantes-raiz/transplantes/21634-figado>>

CHEN, Y. et al. Liver Segmentation from CT Images Based on Region Growing Method. 2009 3rd International Conference on Bioinformatics and Biomedical Engineering. Anais...IEEE, jun. 2009 Disponível em: <<http://ieeexplore.ieee.org/document/5163018/>>

CONCI, A. Extração de Características e Segmentação, 2016. Disponível em: <<http://www2.ic.uff.br/~aconci/segmentacao.PDF>>

GUYTON, A. C.; HALL, J. E. Tratado de Fisiologia Médica. 11. ed. Rio de Janeiro: Elsevier, 2006. v. 2

HUANG, L. et al. Automatic Liver Segmentation from CT Images Using Single-Block Linear Detection. BioMed Research International, v. 2016, 2016.

IHME. United States Mortality Rates by Country 1980-2014, 2014. Disponível em:

<<https://www.kaggle.com/IHME/us-countylevel-mortality/data>>

INSTITUTO NACIONAL DO CÂNCER. Câncer de fígado, 1998. Disponível em: <http://www.inca.gov.br/conteudo_view.asp?id=330>

LIM, S. J.; JEONG, Y. Y.; HO, Y. S. Automatic liver segmentation for volume measurement in CT Images. Disponível em: <<http://ghdx.healthdata.org/record/united-states-mortality-rates-county-1980-2014>>.

MEDINA PESTANA, J. O. et al. Dimensionamento dos Transplantes no Brasil e em cada estado (2009-2016). Registro Brasileiro de Transplantes, p. 89, 2016.

MONTEIRO, R. A. et al. Qualificação das informações de causas externas em sistemas nacionais de informação em saúde no Brasil. [s.l: s.n.].

NOO, F. et al. Computed Tomography. [s.l: s.n.].

RUSKO, L.; BEKES, G. Fully automatic liver segmentation for contrast-enhanced CT images. International Conference on Medical Image Computing and Computer-Assisted Intervention. Segmentation in the Clinic: a grand challenge, 2007, p. 143–150, 2007.

SANTA BÁRBARA, A. Processamento de Imagens Médicas Tomográficas para Modelagem Virtual e Física. [s.l: s.n.].

TAJIMA, T. et al. Computer-aided detection (CAD) of hepatocellular carcinoma on multiphase CT images. v. 6514, p. 65142Q, 2007.

TEIXEIRA, A. C. et al. Liver transplantation . Expectation with MELD score for liver allocation in Brazil. n. may 2001, p. 2004–2006, 2006.

THOMAZ, R. L. et al. Non-deterministic optimization using differential evolution algorithm to launch seeds for liver segmentation in MDCT. IFMBE Proceedings, v. 51, p. 78–81, 2015.

THOMAZ, R. L. et al. Liver segmentation from MDCT using region-growing based on t location-scale distribution. XXV Congresso Brasileiro de Engenharia Biomédica, p. 1139–1142, 2016.

THOMAZ, R. L. et al. One-class SVM for 3D region growing segmentation of liver in Computed Tomography. p. 3–6, 2017.

YANG, B. et al. Prospective study of early detection for primary liver cancer. Journal of cancer research and clinical oncology, v. 123, n. 6, p. 357–60, 1997.