UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

Trabalho de Conclusão de Curso

ALGORITMO DE SEGMENTAÇÃO DO FÍGADO EM TOMOGRAFIAS ATRAVÉS DE TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS

Natália Maniçoba de Araújo

Natal/RN
2023

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

CENTRO DE TECNOLOGIA

DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

ALGORITMO DE SEGMENTAÇÃO DO FÍGADO EM TOMOGRAFIAS ATRAVÉS DE TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS

Trabalho de conclusão de curso apresentado ao Departamento de Engenharia Biomédica da Universidade Federal do Rio Grande do Norte para obtenção do título de Graduado em Engenharia Biomédica.

Graduando: Natália Maniçoba de Araújo

Orientador: Profª Dra. Heliana Bezerra Soares

Natal/RN

2023

Universidade Federal do Rio Grande do Norte - UFRN
Sistema de Bibliotecas - SISBI
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Araujo, Natalia Maniçoba.
Algoritmo de segmentação do fígado em tomografias através de técnicas de processamento digital de imagens / Natalia Manicoba de Araujo. - 2023.
70 f.: il.

Monografia (graduação) - Universidade Federal do Rio Grande do Norte, Centro de Tecnologia, Curso de Engenharia Biomédica, Natal, RN, 2023.
Orientador: Profa. Dra. Heliana Bezerra Soares.

1. Tomografia computadorizada - Monografia. 2. volumetria hepática - Monografia. 3. processamento digital de imagens - Monografia. I. Soares, Heliana Bezerra. II. Título.

RN/UF/BCZM CDU 621.397.331

Elaborado por Ana Cristina Cavalcanti Tinoco - CRB-15/262

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

CENTRO DE TECNOLOGIA

DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

ALGORITMO DE SEGMENTAÇÃO DO FÍGADO EM TOMOGRAFIAS ATRAVÉS DE TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS

Banca Examinadora do Trabalho de Conclusão de Curso:

Prof.ª Dra. Heliana Bezerra Soares _____

UFRN - Orientadora

Eng.ª Luísa Christina de Souza _____

Avaliadora Externa

Eng. José Micael Delgado Barbosa _____

Avaliador Externo

Natal/RN

2023

DEDICATÓRIA

Dedico esse trabalho primeiramente a Deus, pelas bênçãos e força divina; à minha família, que foi meu porto seguro e apoio em busca dessa realização. Em especial, à minha vó Joana, que me colocou em suas orações todos os dias que estive distante do meu lar.

AGRADECIMENTOS

Gostaria de expressar meu profundo agradecimento a todos aqueles que estiveram ao meu lado durante essa jornada do curso de Engenharia Biomédica. Em primeiro lugar, agradeço a Deus por guiar meus passos e iluminar meu caminho ao longo de toda essa trajetória.

A meus pais Selma e Benedito, minha gratidão é imensa. Vocês sempre foram meu porto seguro, o incentivo e dedicação de vocês foram fundamentais para que eu alcançasse meus objetivos. À minha querida irmã Monalisa, obrigada por estar ao meu lado durante toda a vida e o percurso em Natal. Nossos momentos juntos foram preciosos e me fortaleceram. Quero agradecer também a meu namorado Rhyan, por seu constante apoio, amor e compreensão. Sua confiança em mim foi essencial para que eu seguisse em frente.

Agradeço também a meus tios, que me receberam em Natal durante essa nova fase da faculdade. O acolhimento fez toda a diferença em minha adaptação a esse novo ambiente.

A minha amiga de infância Marylia, obrigada por sua amizade sincera e duradoura. Nossa conexão especial e nossa cumplicidade ao longo dos anos foram fundamentais para que eu me sentisse amparada em todos os momentos.

Aos meus grandes amigos, Herlane, Nialison, Hugo, Jackson e Dalyne, que conquistei ao longo do curso de Ciências e Tecnologia, a jornada ao lado de vocês foi marcada por muito aprendizado e diversão. Obrigada William e Dalyne por nossa aproximação ter se fortalecido ainda mais durante o ciclo de Engenharia Biomédica, me ajudaram em diversos momentos importantes. A amizades de todos vocês são tesouros que guardarei para sempre em meu coração.

Por fim, quero expressar minha profunda gratidão à minha querida orientadora e professora Heliana. Sua presença e dedicação foram fundamentais em cada etapa deste trabalho, desde o LABSIM até a finalização dessa conclusão. Agradeço pela paciência, sabedoria e inspiração que você compartilhou comigo, especialmente na área de imagens.

A todos vocês, dedico este trabalho como uma expressão sincera de gratidão. Sei que sem o amor, apoio e contribuição de cada um de vocês, essa conquista não seria possível.

EPÍGRAFE

"Ainda que eu tenha o dom de profecia e saiba todos os mistérios e todo o conhecimento, e tenha uma fé capaz de mover montanhas, mas não tiver amor, nada serei."
(1 Coríntios 13:2)

SUMÁRIO

LISTA DE FIGURAS X
LISTA DE TABELAS XII
LISTA DE EQUAÇÕES XIII
LISTA DE ABREVIAÇÕES, SIGLAS E SÍMBOLOS XIV
RESUMO XV
ABSTRACT XVI
1. INTRODUÇÃO 1
1.1. OBJETIVOS 2
1.1.1. OBJETIVO GERAL 2
1.1.2. OBJETIVOS ESPECÍFICOS 2
1.2. ESTADO DA ARTE 3
1.3. ESTRUTURA DO TRABALHO 5
2. O FÍGADO 5
2.1. ASPECTOS BIOLÓGICOS 6
2.2. TRANSPLANTE HEPÁTICO 8
2.3. DIAGNÓSTICO POR IMAGEM 9
2.3.1. TOMOGRAFIA COMPUTADORIZADA 9
2.3.1.1. PADRÃO DICOM 12
2.3.1.2. IMAGEM TOMOGRÁFICA DE FÍGADO 13
3. PROCESSAMENTO DIGITAL DE IMAGENS 16
3.1. FUNDAMENTOS DA IMAGEM 17
3.2. TRANSFORMAÇÕES DE INTENSIDADE 17
3.2.1. HOUNSFIELD 17
3.2.2. JANELAMENTO 18
3.3. RESTAURAÇÃO DA IMAGEM 19
3.3.1. FILTRAGEM ESPACIAL 19
3.3.1.1. FILTRO MEDIANA 19
3.3.2. FILTROS DE REALCE E SUAVIZAÇÃO 20
3.3.2.1. FILTRO DE DIFUSÃO ANISOTRÓPICO 20

3.3.3. FILTRAGEM DE MÍNIMO ERRO QUADRÁTICO MÉDIO 21
3.4. SEGMENTAÇÃO DE IMAGENS 22
3.4.1. AGRUPAMENTO (CLUSTERING) 22
4. ALGORITMO DE SEGMENTAÇÃO DO FÍGADO 24
4.1. BASE DE DADOS 25
4.2. PRÉ-PROCESSAMENTO 27
4.2.1. HOUNSFIELD 27
4.2.2. JANELAMENTO 28
4.2.3. FILTRO MEDIANA 30
4.2.4 FILTRO DE DIFUSÃO ANSIOTRÓPICO 30
4.2.5 FILTRO DE WIENER 31
4.3. PROCESSAMENTO 31
4.3.1. SEGMENTAÇÃO *K-MEANS* 31
4.3.1.1. ROTULAÇÃO DOS COMPONENTES CONECTADOS 32
4.4. PÓS-PROCESSAMENTO 33
4.4.1. EXTRAÇÃO DO FÍGADO 33
5. RESULTADOS E DISCUSSÕES 35
5.1. RESULTADOS DO ALGORITMO DE SEGMENTAÇÃO DO FÍGADO . 36
5.2. COMPARAÇÃO ENTRE A MÁSCARA MODELO E A SEGMENTAÇÃO PROPOSTA 41
5.2.1. VOLUMETRIA HEPÁTICA 42
5.2.2. TAXA DE ACERTO E ERRO QUADRÁTICO MÉDIO 45
5.2.3. COEFICIENTE DE SØRENSEN-DICE 47
5.2.4. DIFERENÇA DE VOLUME ABSOLUTO RELATIVO 48
6. CONCLUSÕES 49
6.1 TRABALHOS FUTUROS 51
7. REFERÊNCIAS 52

LISTA DE FIGURAS

Figura 1: Anatomia do Fígado. a) Secção transversal região superior do abdome, b) posição do fígado e estruturas, c) Face diafragmática na superfície anterior do fígado e d) A fase visceral na superfície ínfero-posterior do fígado. 7
Figura 2: Sistema de aquisição de imagens. (a) corte único e (b) multicorte. 11
Figura 3: Imagens de TC tórax e abdome. 11
Figura 4: Segmentação hepática proposta por Couinaud. (a) Fração superior e (b) Fração inferior do fígado. 14
Figura 5: Anatomia segmentar do Fígado. (a) Visão geral, (b) Lobo caudado, (c) Subsegmento lateral superior esquerdo, (d) Lateral inferior esquerdo, (e) Medial esquerdo, (f) Medial esquerdo inferior, (g) Anteroinferior direito, (h) Subsegmento anterossuperior direito, (i) Subsegmento póstero inferior direito e (j) Subsegmento póstero superior direito. 15
Figura 6: Aplicação do janelamento em diferentes distribuições de escalas. (a) janela para tecidos ósseos, (b) janela para tecidos moles e (c) janela para pulmões. 19
Figura 7: Filtragem Mediana. (a) Imagem de placa de circuito com ruído e (b) Redução de ruído com filtro mediana 3x3. 20
Figura 8: Resultado do filtro Wiener. (a) Imagem com ruído e (b) Filtro Wiener. . 21
Figura 9: Exemplo de aplicação do algoritmo de agrupamento *K-means* para vários valores de K. (a) K = 2, (b) K = 3, (c) K = 10 e (d) Imagem Original. 23
Figura 10: Diagrama de bloco com os métodos utilizados no processo. 25
Figura 11: Exemplo de fatia Nº 54 do exame 11. (a) Fatia de TC sem nenhum processamento e (b) Imagem após aplicação HU. 28
Figura 12: Imagem com janelamento. 29
Figura 13: Resultado da fatia depois do filtro mediana. 30
Figura 14: Resultado da fatia depois da filtragem difusa. 30
Figura 15: *Slice* resultante depois da Filtragem de Wiener. 31
Figura 16: Fatias do exame 11 depois da segmentação *K-means* com 5 *Clustering*. (a) Fatia de TC do nº 12, (b) Fatia de TC do nº 52, (c) Fatia de TC do nº 115 e (d) Fatia de TC do nº 137. 32
Figura 17: Fatia de um paciente depois da rotulação dos componentes conectados. 33

Figura 18: Extração da primeira parte do fígado em função do atributo tamanho.34
Figura 19: Extração da segunda parte do fígado em função do atributo do diâmetro equivalente. 35
Figura 20: Ilustração das fatias originais do exame 11 de TC com a segmentação automática do fígado destacada na coloração vermelha. 37
Figura 21: Diagrama de bloco com os resultados do exame 11..... 38
Figura 22: Ilustração das fatias originais do exame 12 de TC com a segmentação automática do fígado destacada em coloração vermelha. 39
Figura 23: Diagrama de bloco com os resultados do exame 12..... 40
Figura 24: Fatias paciente 11. (a) e (b) Fatia 12, (c) e (d) Fatia 52, (e) e (f) Fatia 115, e (g) e (h) Fatia 137..... 41
Figura 25: Visualização do fígado em 3D. (a) e (b) Fígado em 3D do exame 11, (c) e (d) Fígado em 3D do exame 12, (e) e (f) Fígado em 3D do exame 13, (g) e (h) Fígado em 3D do exame 2 e (i) e (j) Fígado em 3D do exame 1. 44

LISTA DE TABELAS

Tabela 1: Exemplos de DICOM *Tags* relevantes para processamento digital de tomografias..... 12
Tabela 2: Nomenclatura norte-americana e internacional para os segmentos hepáticos de Couinaud..... 14
Tabela 3: Valores de Hounsfield para tecidos presentes na literatura. 18
Tabela 4: Quantidade de Exames de TC abdominal contemplados na base de dados. 26
Tabela 5: Exemplos de volume de fatias do Exame 11..... 38
Tabela 6: Exemplos de volume de fatias do Exame 12..... 39
Tabela 7: Volumes calculados com as imagens modelos fornecidas na base e volume calculados pelo algoritmo proposto no trabalho..... 43
Tabela 8: Volumes calculados com as imagens modelos fornecidas na base e volume calculados pelo algoritmo de segmentação automática propostas e suas respectivas taxas de acerto para cada exame. 45
Tabela 9: Erro quadrático médio para cada exame..... 46
Tabela 10: Volumes calculados com as imagens modelos fornecidas na base e volume calculados pelo algoritmo de segmentação automática com as técnicas propostas e seus respectivos coeficientes de DICE..... 48
Tabela 11: Volumes calculados com as imagens modelos da base e volume calculados pelo algoritmo proposto e as respectivas diferenças relativa do volume absoluto..... 49

LISTA DE EQUAÇÕES

Equação (1): Atenuação Hounsfield ……..…… 17
Equação (2): Filtro de Difusão Anisotrópico ……..... 20
Equação (3): Filtragem de Mínimo Erro Quadrático Médio ……..…… 21
Equação (4): Hounsfield …….. 28
Equação (5): Janelamento ……... 29
Equação (6): Volume de uma fatia ……..... 42
Equação (7): Volume total do fígado ……..... 42
Equação (8): Taxa de acerto ……..... 45
Equação (9): Erro Quadrático Médio ……..... 46
Equação (10): Coeficiente de Sorensen-DICE ……..... 47
Equação (11) – Diferença de Volume absoluto relativo ……..... 48

LISTA DE ABREVIAÇÕES, SIGLAS E SÍMBOLOS

CH – Cirrose Hepática

ACS – *American Cancer Society*

INCA – Instituto Nacional do Câncer

TH – Transplante Hepático

TC – Tomografia Computadorizada

RM – Ressonância Magnética

***VOXEL* –** *Volume Element*

DICOM – *Digital Imaging and Communications in Medicine*

ACR – *American College of Radiology*

NEMA – *National Electricall Manufacturers Association*

CHAOS - *Combined (CT-MR) Healthy Abdominal Organ Segmentation*

MATLAB – *MATrix LABoratory*

HU – *Hounsfield*

WC – *Window Center*

WW – *Window Width*

TA – Taxa de Acerto

EQM – Erro Quadrático Médio

DICE – *Dice Coefficient*

RAVD – *Relative Absolute Volume Difference*

ARAÚJO, Natália Maniçoba. **Algoritmo de Segmentação do Fígado em Tomografias através de técnicas de processamento digital de imagens.** Trabalho de Conclusão de Curso, Graduação em Engenharia Biomédica, Universidade Federal do Rio Grande do Norte, 71p., 2023.

RESUMO

O fígado desempenha um papel importante no funcionamento harmonioso do corpo humano. Para complicações hepáticas que requerem intervenção cirúrgica, a localização e volume do órgão são analisados por tomografia computadorizada dinâmica, devido ao curto tempo de aquisição, ampla faixa de imagem e alta resolução espacial. Apesar das vantagens, apresenta inúmeras dificuldades por causa das características físicas da região. Por exemplo, na tomografia computadorizada, existem vários órgãos adjacentes, como o pâncreas e o estômago, que apresentam níveis de intensidade semelhantes ao fígado. Dessa forma, este trabalho teve como objetivo realizar a segmentação do fígado com auxílio de técnicas de processamento de imagens médicas em tomografias do abdome superior para implementar o cálculo do volume hepático e visualização da estrutura em três dimensões, devido a sua importância no planejamento de cirurgias, principalmente para analisar possíveis doadores para transplante hepático, onde o conhecimento do volume e localização possibilita tratamentos e procedimentos cirúrgicos mais eficazes. No processamento da imagem foi aplicado técnicas de segmentação e aprendizado não supervisionado, onde obteve taxa de acerto média de 87,77% e máxima de 98,23%.

Palavras-chave: Transplante hepático; tomografia computadorizada; processamento digital de imagens e volumetria hepática.

ARAÚJO, Natália Maniçoba. **Liver Segmentation Algorithm in Tomography using digital image processing techniques.** Completion of course work, Graduation in Biomedical Engineering, Federal University of Rio Grande do Norte, 71p., 2023.

ABSTRACT

The liver plays an important role in the harmonious functioning of the human body. For liver complications that require surgical interventions, the location and volume of the organ are analyzed by dynamic computed tomography, due to the short acquisition time, wide image range and high spatial resolution. Despite the advantages, it presents numerous difficulties due to the physical characteristics of the region. For example, in the CT scan, there are several adjacent organs, such as the pancreas and the stomach, which have similar intensity levels to the liver. Thus, this study aimed to perform the segmentation of the liver with the aid of medical image processing techniques in CT scans of the upper abdomen to implement the calculation of liver volume and visualization of the structure in three dimensions, due to its importance in the planning of surgeries, mainly to analyze possible donors for liver transplantation, where knowledge of the volume and location enables more effective treatments and surgical procedures. In image processing, segmentation and unsupervised learning techniques were applied, obtaining an average success rate of 87.77% and a maximum of 98.23%.

Keywords: Liver transplantation; computed tomography; digital image processing and liver volumetry.

1. INTRODUÇÃO

Em 2021, o Brasil ocupa o terceiro lugar entre 35 países em número de transplantes hepáticos (TH) realizados, com um total de 2.044 transplantes de fígado realizados, sendo 1.880 de doadores falecidos, 164 de doadores vivos,144 de parentes e 20 foram de não parentes (ABTO, 2022). O TH se torna uma alternativa em decorrência de doenças como cirrose, insuficiência hepática que resulta na falência de órgãos, necessitando de assistência ventilatória enquanto ficam na fila de espera aguardando por um doador compatível (THULUVATH, 2018).

De acordo com Registro Brasileiro de Transplantes (RBI), o Brasil em 2022 obteve um aumento de 3,62% em transplantes hepáticos realizados com relação ao ano anterior, totalizando em 2.118 transplantados. Dessa forma, um aumento de 3,78% onde são doadores falecidos, 1,83% para doadores vivos, 0,7% para doações de parentes e 10% para não parentes comparados aos dados do ano de 2021 (ABTO, 2022).

A tomografia computadorizada dinâmica fornece imagens detalhadas do órgão para análise de possíveis doadores e receptores com objetivo de identificar as alterações hepáticas, pois permite uma visualização precisa das estruturas devido ao curto tempo de aquisição, ampla faixa de imagem e alta resolução espacial (Y. MASUTAMI, 2006). Entretanto, apresenta como desafio as distribuições de níveis de intensidades semelhantes a outros órgãos próximos, como por exemplo, o estômago, baço, rins e coração, o que resulta nas bordas não delimitadas do fígado (ARAÚJO, 2022).

A forma e tamanho do fígado pode variar bastante de um paciente para outro, dessa forma, a segmentação do fígado em tomografias tem sua grande importância e utilização para discussão do tratamento e planejamento de cirurgia hepática, principalmente nos casos em que o paciente necessita de transplante de fígado, pois são procedimentos complexos que exigem alta precisão. Outro fator relevante, além da extração do órgão, consiste também no conhecimento da volumetria e sua localização possibilitando analisar e mapear a região para verificar possíveis doadores e receptores (MOGHBEL, 2018).

Ao avaliar os resultados da tomografia de abdômen, o especialista tem como desafio verificar diversas características do fígado, como morfologia, forma, tamanho e textura (RIBEIRO, 2007). Com a confirmação diagnóstica, e dependendo das condições e complicações pode ser orientado ao tratamento, mudanças no estilo de vida, medicamentos ou transplante. Portanto, as abordagens corretas para planejamento cirúrgico podem aumentar significativamente as chances de um tratamento bem-sucedido e melhora na qualidade de vida no pós-operatório.

A segmentação semi-automática ou automática vem se destacando nos últimos anos no âmbito da medicina, pois possibilita ganho de tempo comparado a segmentação manual, que em média tem duração de 2 horas para o radiologista delimitar a região de interesse em exames de tomografias (MENDES, 2013; MOGHBEL, 2018).

Com base no descrito acima, este trabalho aplica técnicas básicas de processamento digital de imagens em uma estratégia algorítmica, com o intuito de melhorar a visualização e realçar a região de interesse nas imagens em estudo, para auxiliar o profissional na *análise* do fígado sem a sobreposição de artefatos.

1.1. OBJETIVOS

1.1.1. OBJETIVO GERAL

Desenvolvimento de algoritmo de segmentação do fígado em imagens médicas de tomografias do abdome superior, com a finalidade de extrair o cálculo do volume hepático e visualização da estrutura em três dimensões para auxílio na avaliação médica.

1.1.2. OBJETIVOS ESPECÍFICOS

Para o desenvolvimento deste trabalho, foi necessário descrever os seguintes pontos, relacionado ao projeto:

1. Entender sobre as características do órgão em estudo;
2. Realizar a revisão bibliográfica, nas áreas envolvidas no trabalho.
3. Selecionar uma base de dados.
4. Analisar e estudar técnicas de processamento digital de imagens.

5. Selecionar as ferramentas a serem utilizadas no trabalho para segmentação da região de interesse.
6. Escolher a linguagem de programação aplicada ao longo do projeto.
7. Criar o algoritmo proposto.
8. Implementar a estratégia algorítmica.
9. Testar e comparar os resultados obtidos com modelos da base de dados.

1.2. ESTADO DA ARTE

Anastácio (2015), utilizou no trabalho o algoritmo de crescimento de região e lançamento de semente, com o objetivo de realizar a segmentação automática do fígado e posteriormente calcular a volumetria. Para o lançamento das sementes, foi automatizado em formatos retangular, elíptica e circular, o que favoreceu no desempenho do algoritmo e taxa de acerto do volume. Conseguiu alcançar acerto médio de 66,08% para lançamento de semente com região retangular, para região elíptica obteve 75,56% e 99,14% para sementes em região circular. Os resultados foram comparados com a segmentação manual das imagens realizadas por alunos de iniciação científica e validadas pelo especialista.

Kavur *et al.* (2021), abordou o desafio CHAOS (*Combined (CT-MR) Healthy Abdominal Organ Segmentation*), composto por segmentações de órgãos abdominais saudáveis em imagens de tomografia computadorizada (TC) e ressonância magnética (RM). No estudo avaliou os algoritmos de segmentação eficientes para delinear automaticamente fígado, baço e rins. Além da avaliação, discutiram as dificuldades e desafios envolvidos no processo de extração desses órgãos, apresentando uma análise comparativa entre os resultados obtidos pelos participantes. Os melhores DICE foi o desempenho do PKDIA com DICE (0,98 ± 0,00) e RAVD (%) de (1,32 ± 1,30).

Selvalakshmi *et al.* (2017), forneceu uma abordagem para segmentação e visualização 3D do fígado, lesões e vasos sanguíneos presentes em imagens de angiotomografia computadorizadas do abdômen. Para segmentar a estrutura de interesse, os autores aplicaram técnicas de pré-processamento para melhoria na qualidade e uniformidade das imagens, posteriormente segmentação baseada em limiarização para detecção das lesões, bordas vasculares e rastreamento dos vasos. A tarefa final após a conclusão de todas as segmentações foi combinar os

resultados obtidos dos algoritmos de segmentação do fígado, lesões e vasos sanguíneos para produzir uma visualização 3D completa das estruturas.

Kaczor *et al.* (2022), realizou a comparação de métodos de pré-processamento de imagens para a tarefa de segmentação do fígado. Os autores investigaram a eficácia dos métodos de pré-processamento como, filtragem espacial, normalização de intensidade, ajuste de contraste e equalização de histograma para eliminar ruídos e realçar as estruturas. Os resultados foram avaliados com base na sobreposição de *Ground Truth* e erro de segmentação. Os autores apresentaram as vantagens e desvantagens de cada método testado, a importância do pré-processamento na área médica e forneceram *insights* valiosos para futuros trabalhos na área.

Islam *et al.* (2021), avaliou diferentes técnicas de processamento para segmentação automática do fígado baseada em U-Net, uma arquitetura de rede neural convolucional com habilidade de aprendizado de características, essa técnica tem a capacidade de preservar detalhes finos. No estudo foi utilizado dados de imagens de ressonância magnética, e aplicado pré-processamento como equalização de histograma, filtragem bilateral, filtragem gaussiana e normalização de intensidade. As imagens foram usadas para treinamento e teste com a rede neural. A métrica de avaliação foi o coeficiente de DICE que obteve 96,24%, 90,48% e 90,04% nas imagens de treinamento, validação e testes, respectivamente.

Leite (2017), investigou o desempenho de duas técnicas disponíveis na literatura, e comparou duas abordagens principais: a segmentação 2D, que realiza a segmentação em cada fatia de imagem individualmente, e a segmentação 3D, que leva em consideração as informações volumétricas das imagens. A avaliação e comparação das técnicas foram realizadas com base em critérios como precisão da segmentação, sobreposição com a segmentação manual e tempo de processamento. Com base nos resultados, obteve um acerto médio de 66,08% para segmentação com lançamento de semente retangular, 75,56% para região elíptica e 91,14% para região circular, o autor concluiu que as técnicas de segmentação 3D apresentaram uma tendência de obter resultados mais precisos em comparação com as técnicas 2D. No entanto, as técnicas 3D exigiram um tempo de processamento mais longo.

Fang (2020), descreveu o progresso do uso de modelos 3D, situação atual, desafios e capacidade de melhorias para obter diretrizes operacionais mais rigorosas para diagnóstico e gerenciamento de visualização 3D em doenças hepáticas e tornar a tecnologia mais madura. Aplicou critérios e etapas para pontualidade de qualidade e melhorar a eficácia do modelo.

Mendes (2013), desenvolveu três tipos de segmentação 3D, a primeira técnica utiliza imagens de Tomografia Axial Computorizada, na segunda de Tomografia por Emissão de Positrões e na terceira de ambos os tipos. Obteve resultados aceitáveis na modalidade TAC, devido a qualidade da imagem. Enquanto a segmentação TEP apresentou resultados inferiores.

1.3. ESTRUTURA DO TRABALHO

Esse trabalho foi dividido em 6 seções: na seção 2 compreende os aspectos da anatomia do órgão, definição do transplante hepático e seus desafios. Além disso, os conceitos sobre o padrão das imagens DICOM fornecidos através do exame de tomografia computadorizada. A seção 3 aborda a teoria dos métodos de processamento digital de imagens estudados para facilitar e auxiliar o profissional no acesso à informação. Na seção 4 detalha o desenvolvimento do algoritmo, a escolha da base de dados, e especificações das estratégias utilizadas. A seção 5 exibe os resultados e discussões obtidos com a segmentação do fígado gerando o seu volume hepático, e as métricas como taxas de acerto, erro quadrático médio, coeficiente de *SØrensen-Dice* e diferença relativa. Por fim, a seção 6 expõem a conclusão e considerações finais, com as perspectivas de trabalhos futuros.

2. O FÍGADO

O fígado desempenha muitas funções diferentes que se correlacionam. Representa o local primário de secreção da bile, desintoxicação das substâncias e resíduos absorvidos pelo sistema digestório. Além disso, também tem função de processar, armazenar e redistribuir substâncias como glicose, aminoácidos e ácidos graxos. Assim, devido a alta atividade metabólica e funções vitais, o consumo excessivo de álcool, utilização não moderada de medicamentos, e estilo de vida pouco saudável, torna o órgão vulnerável à lesão celular, infecções e fibrose (MORRE, 2014).

2.1. ASPECTOS BIOLÓGICOS

Depois da pele, o fígado desempenha o papel de maior órgão do corpo humano, possui peso em torno de 1,5kg em uma pessoa adulta. Dessa forma, grande quantidade de sangue pode ser armazenada em seus vasos, tornando um órgão com elevado fluxo sanguíneo e baixa resistência vascular. Varia em média total de 1.350 mL/min de sangue que fluem da veia porta para os sinusoides hepáticos e sinusoides da artéria a cada minuto. A pressão na entrada do fígado varia em torno de 9mmHg, uma resistência ao fluxo sanguíneo muito baixa, levando em consideração a quantidade de sangue que flui por essa via a cada minuto (GUYTON; HALL, 2006).

Os nutrientes absorvidos pelo trato gastrointestinal, com exceção da gordura, são inicialmente levados para o fígado pelo sistema venoso porta. Além disso, são realizadas muitas atividades metabólicas, armazenamento de glicogênio e secreção da bile (MORRE, 2014).

O fígado possui uma face diafragmática convexa e uma face visceral plana (póstero-anterior), que são separadas anteriormente por sua margem inferior aguda, conforme ilustrado na Figura 1. Na fase diafragmática do fígado tem características lisa e em forma de cúpula, coberta por peritônio visceral. Próximo ao ápice do fígado cuneiforme, as lâminas anterior e posterior da parte esquerda do ligamento coronário se encontram para formar o ligamento triangular esquerdo. O plano essencialmente mediano definido pela fixação do ligamento falciforme e fissura sagital esquerda separa um lobo direito grande de um lobo esquerdo muito

menor. Na face visceral do fígado inclinada, as fissuras sagitais circundam e a porta do fígado transversa demarca dois lobos acessórios: o lobo quadrado anterior e o lobo caudado posterior (MARTINI,2014).

Figura 1: Anatomia do Fígado. a) Secção transversal região superior do abdome, b) posição do fígado e estruturas, c) Face diafragmática na superfície anterior do fígado e d) A fase visceral na superfície ínfero-posterior do fígado.

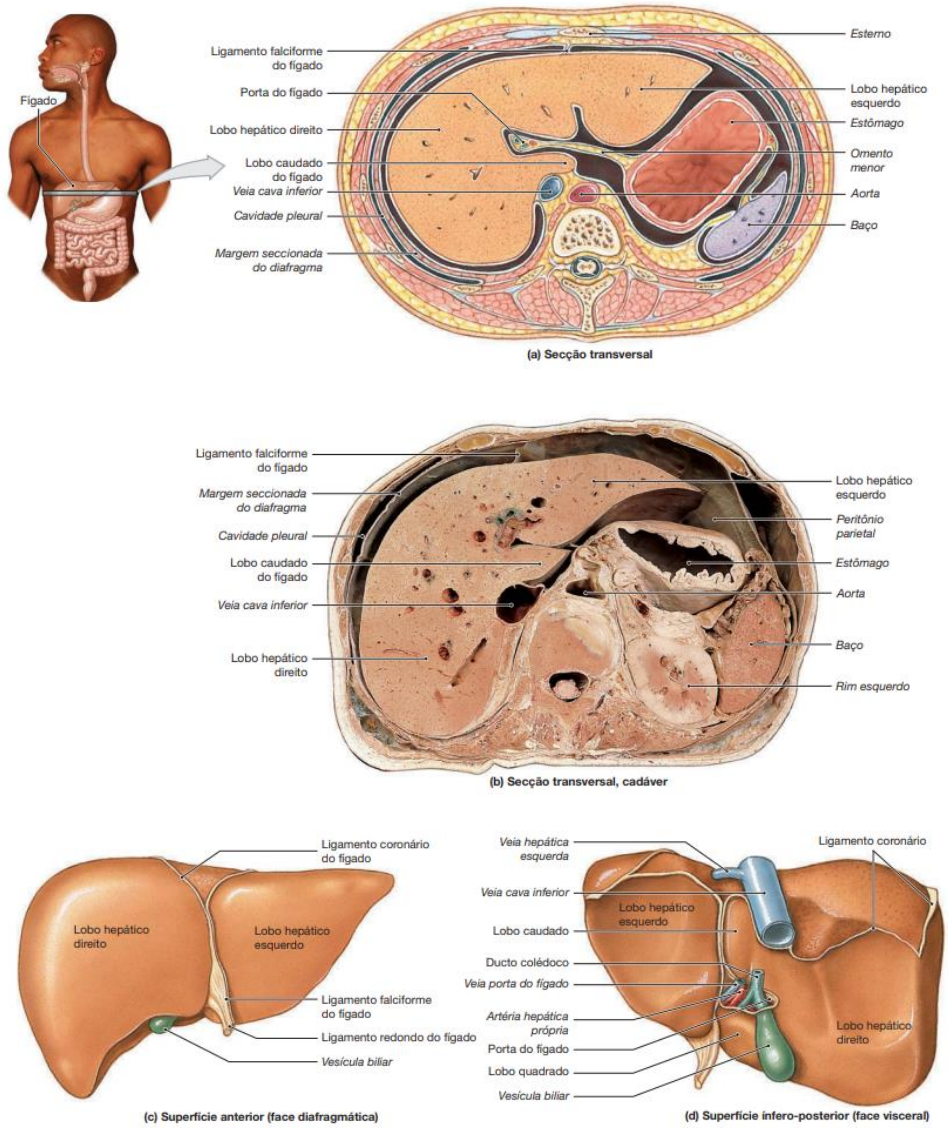

Fonte: (MARTINI, 2014).

O líquido bile fica armazenado na vesícula biliar e produzido pelo fígado, tem como função a emulsificação da gordura que entra no duodeno, para que seja facilmente digerida e ocorra a regulação da acidez dentro do intestino. A função

hepática desempenha um papel importante no metabolismo de nutrientes, como carboidratos, lipídios e proteínas. A glicose pode ser armazenada na forma de glicogênio e liberada quando necessário para manter os níveis adequados de açúcar no sangue. Além disso, o fígado realiza síntese de proteínas importantes como a albumina e enzimas (GUYTON; HALL, 2006).

Em vista disso, a estrutura anatômica do fígado e suas funções fisiológicas são fundamentais para a manutenção da homeostase e o funcionamento dentro das conformidades de diversos sistemas do organismo (MORRE, 2014).

2.2. TRANSPLANTE HEPÁTICO

Ao se deparar com pacientes em estágios avançados de doenças hepáticas, aplica atualmente como conduta na maioria dos casos o transplante hepático (TH), onde as alternativas de tratamentos estão esgotadas e as complicações comprometem a qualidade de vida do indivíduo (TORRES, 2019).

No TH ocorre a substituição do órgão doente por outro saudável proveniente de um doador vivo ou falecido, e tem como indicações pacientes com complicações da cirrose, insuficiência hepática aguda, doença hepática crônica entre outras. Apesar do grande número de transplantes realizados, possui alta taxa de complicações que resulta na mortalidade dos transplantados (SCHOLLEMBERG, 2019).

No Brasil, o primeiro transplante de fígado com sucesso a longo prazo foi realizado em 1985, no Hospital das Clínicas da Universidade de São Paulo, pela equipe de Silvano Raia (MIES, 1998). Ocorreu muitos avanços no Brasil, quando se refere aos transplantes, sendo classificado como um dos países com maior número de transplantes realizados (BRASIL, 2003).

Necessita que seja realizado uma avaliação rigorosa no doador, como também no receptor, a fim de minimizar os riscos durante o procedimento cirúrgico e no pós-operatório, referente a complicações como rejeição do órgão, infecção, hemorragia e entre outras. Dessa forma, para auxiliar no mapeamento a visualização 3D total da região por meio da segmentação automática tem como vantagem o ganho de tempo, não sendo necessário que o especialista delimite manualmente (MENDES, 2013; MOGHBEL, 2018).

Grandes avanços ocorreram nos últimos 20 anos em relação a evolução dos transplantes hepáticos, entretanto o paciente pode ser submetido a complicações relacionados ao enxerto, onde pode ocorre rejeição hiperaguda, aguda ou crônica, complicações também ocorre com relação a cirurgia, como por exemplo hemorragias, e por fim, complicações clínicas, como infecção por vírus ou bactérias (TORRES, 2019).

O procedimento cirúrgico pode resultar em morte também para o doador, com o intuito de reduzir essa probabilidade, existem atualmente variáveis que são observadas referente ao doador, como: idade, sexo, se possui diabetes ou hipertensão, grau do enxerto, tempo de isquemia fria e quente, sorologia e a combinação das idades entre os dados e o receptor, essas variáveis auxilia os centros de transplantadores a não utilizarem doadores não ideais (TORRES, 2019).

2.3. DIAGNÓSTICO POR IMAGEM

Os tipos de exames de imagem mais utilizados na área médica são raios X, ultrassonografia, tomografia computadorizada e ressonância magnética, pois atualmente chegam bem próximos a anatomia humana, e auxiliam o profissional definir suas condutas no momento do diagnóstico (MOREIRA *et al.,* 2017).

A aplicação e o avanço de tecnologias digitais inteligentes para diagnóstico e tratamento em cirurgia hepática tornaram a visualização 3D do fígado o método mais eficaz, permitindo que os cirurgiões entendam totalmente a complexa anatomia interna do fígado. Assim, possibilita uma representação personalizada da complexa anatomia interna do fígado e uma visão relativamente abrangente para apoiar a tomada de decisões clínicas, fornecendo informações espaciais sobre o fígado e seus órgãos circundantes (FANG, 2020).

A próxima seção descreve o diagnóstico por imagem usando tomografia computadorizada, método este selecionado para realizar a análise neste trabalho, disponível na base de dados estudada.

2.3.1. TOMOGRAFIA COMPUTADORIZADA

A tomografia computadorizada (TC) começou a ser utilizada como método diagnóstico no início da década de 1970, teve difusão nos anos 1980 e cada vez

mais utilizada na prática médica porque permite observar as estruturas internas do corpo humano por meio de cortes anatômicos denominados “varredura”. A palavra tomográfica significa “imagem em tomos”, essa definição se refere a imagem aplicada em planos, ou seja, pode ser gerada a partir de um plano de corte (MOURÃO *et al.,* 2009).

As imagens tomográficas são reconstruídas através de elevado número de medições de atenuação do feixe de raios X em diversas posições do sistema tubo-detector em relação ao objeto. Os detectores captam a parcela do feixe que atravessa o objeto gerando um sinal elétrico, que depois convertido em um sinal digital e enviado para o computador. Após a aquisição de várias medições, o computador faz o tratamento dessas informações para determinar a parcela do feixe que foi absorvida por cada um dos *voxels* que compõem a fatia irradiada, que está associada ao valor do coeficiente de atenuação linear do tecido que compõe cada *voxel* (MOURÃO *et al.,* 2009).

A partir da imagem digital são aplicados ajustes de contraste, brilho, intensidade, reconstrução etc. O tratamento dos cortes permite gerar imagens de volume, flexibilizando ainda mais a utilização dessa tecnologia para auxiliar no diagnóstico (BRANT; HELMS, 2014).

Os aparelhos de TC de corte único geram a imagem de cada plano de corte em um procedimento distinto, denominada aquisição axial. Esse processo consiste em dividir em etapas de aquisição de dados para cada corte de maneira independente. Assim, o paciente posicionado na mesa, que se desloca e estaciona, e o tubo de raios X dá uma volta completa em torno do paciente para um corte. A seguir, a mesa se desloca novamente e para, e o tubo dá outra volta e esse ciclo se repete o número de vezes correspondente ao número de imagens de corte que se deseja obter (MOURÃO *et al.,* 2009).

Por outro lado, existem aparelhos de tomografia computadorizada multicorte, onde para cada volta completa do tubo de raios X em torno do paciente, são feitas aquisições de dados de mais de um corte simultaneamente, o que diminui o tempo de aquisição das imagens de uma varredura. O número de cortes possíveis depende do número de fileiras de detectores disponíveis no aparelho (Figura 2) (BRANT; HELMS, 2014).

Os aparelhos de tomografia computadorizada mais modernos permitem uma colimação do feixe de até 0,5mm, sendo comuns espessuras de 1mm, 2mm, 5mm e 10mm. Como a escolha de uma espessura de feixe muito pequena resulta em um maior número de cortes, isso implica em aumento no número de imagens geradas e no tempo de exame (MOURÃO *et al.,* 2009).

Figura 2: Sistema de aquisição de imagens. (a) corte único e (b) multicorte.

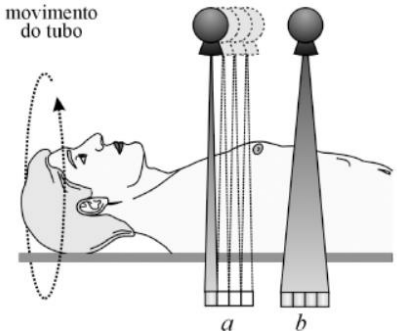

Fonte: (MOURÃO *et al.,* 2009).

Com a evolução da tecnologia, o uso das tomografias modernas tem grande vantagem quando comparadas a outras técnicas de imagem, pois à aquisição dos dados utilizam de processamento paralelo rápido que gera o volume para reconstrução 3D das imagens. Ocorre a partir do empilhamento de todas as fatias e processamento da imagem para visualização total da região (ACHARYA; RAY, 2005).

Figura 3: Imagens de TC tórax e abdome.

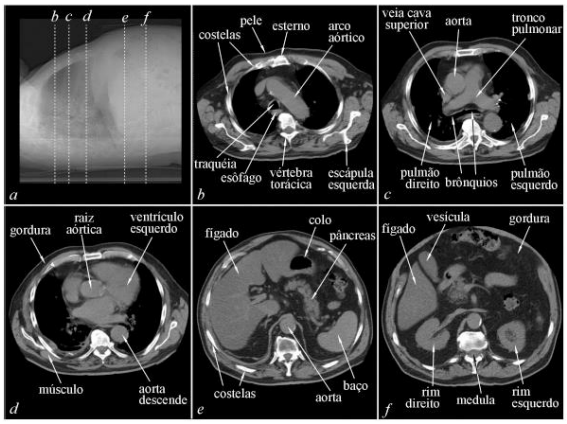

Fonte: (MOURÃO *et al.,* 2009).

Os equipamentos de tomografia computadorizada (TC) são amplamente utilizados para gerar imagens em cortes transversais (axiais) (Figura 3) do corpo

humano (MOURÃO *et al.,* 2009). Essas imagens são as mais comuns e relevantes para a produção do diagnóstico médico, tornando a TC uma ferramenta diagnóstica indispensável.

2.3.1.1. PADRÃO DICOM

Digital Imaging and Communications in Medicine (DICOM) utilizado para padronizar a comunicação e gerenciamento de informações referentes a imagens médicas. Facilita a interoperabilidade e troca de informações entre equipamentos e outros sistemas. Foi definido um padrão pela *American College of Radiology* (ACR) e a *National Manufacturesrs Association* (NEMA) em 1983, quando se surgiu a necessidade de transferir imagens e informações entre dispositivos de fornecedores diferentes, esse método extensamente utilizado até os dias atuais (NEMA, 2023).

No arquivo DICOM as informações são estruturadas em pequenas entidades chamadas DICOM *Tags*. Cada identificação possui um *Tag* ID e outro *Tag Value* que representa um valor específico no formato (XXXX,XXXX), como exemplo na *Tag* (0008,0008), onde cada uma possui um número de 16 *bits*, divididos em grupos reconhecidos pelos primeiros quatros dígitos da *Tag* (ANASTÁSIO, 2015).

Em tomografias existem 132 *Tags* diferentes organizadas no cabeçalho da imagem com informações importantes, como identificação do paciente, tipo de imagem, data de aquisição, parâmetros utilizados na aquisição e entre outros (Tabela 1) (DICOMLIBRARY, 2013). Neste trabalho foi destacado os principais itens do cabeçalho da imagem DICOM que são úteis para análise da imagem e aplicação de processamento digital das imagens.

Tabela 1: Exemplos de DICOM *Tags* relevantes para processamento digital de tomografias.

Número	Nome	Significado
(0008,0008)	*Image Type*	Identificação das características da imagem.
(0008,0060)	*Modality*	Específica qual o tipo da imagem.
(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 *pixel*s armazenados para cada amostra de *pixel* na fatia.
(0028,0102)	*High Bit*	*Pixel* mais significante na amostra de dados dos *pixels.*
(0028,1050)	*Window Center*	Define o centro da janela para exibição.
(0028,1051)	*Window Width*	Define o centro da janela para exibição.
(0028,1052)	*Rescale Intercept*	Representa o ajuste linear aplicado aos valores de *pixel*.
(0028,1053)	*Rescale Slope*	Representa o ajusta da inclinação aplicada aos valores de *pixel*.
(0028,0030)	*Pixel Spacing*	Distância física entre os *pixel*s na fatia em milímetro.
(0018,9311)	*Spiral Pitch Factor*	Relação entre o avanço da mesa por rotação.

Fonte: Adaptado de (Anastácio, 2015) e (DICOMLIBRARY, 2013).

2.3.1.2. IMAGEM TOMOGRÁFICA DE FÍGADO

O diagnóstico por imagem permite avaliar e realizar o estudo anatômico da localização da lesão e planejamento cirúrgico do tipo de ressecção a ser realizada. Posteriormente calcula o volume do fígado no pré e pós-operatório (BITTENCOURT *et al.,* 2014).

Em 1957, cirurgião francês Claude Couinaud propôs os Segmentos de Couinaud, uma classificação anatômica do fígado que fornecesse a identificação padronizada dos segmentos hepáticos, muito relevante e amplamente utilizada em cirurgias hepáticas e intervenções radiológicas no que se diz respeito à aquisição e análise de imagens do fígado (BRANT; HELMS, 2014).

São oitos segmentos distintos que separam o fluxo e o influxo vasculares e a drenagem biliar, sendo que cada um deles pode ser ressecado sem danificar os outros segmentos. Na tomografia do fígado (Figura 4) ilustra a classificação de Couinaud que enumera os segmentos do fígado. O plano longitudinal da veia hepática direita divide o segmento VIII do VII na parte superior do fígado e o V do VI na porção inferior. O plano longitudinal da veia hepática média através da fossa vesicular separa o segmento IVa do VIII na parte superior e o IVb do V na parte inferior. O plano longitudinal da veia hepática esquerda e fissura do ligamento

redondo separa o segmento IVa do II na parte superior e o IVb do III na parte inferior (Tabela 2) (MORRE, 2014) (BRANT; HELMS, 2014).

Figura 4: Segmentação hepática proposta por Couinaud. (a) Fração superior e (b) Fração inferior do fígado.

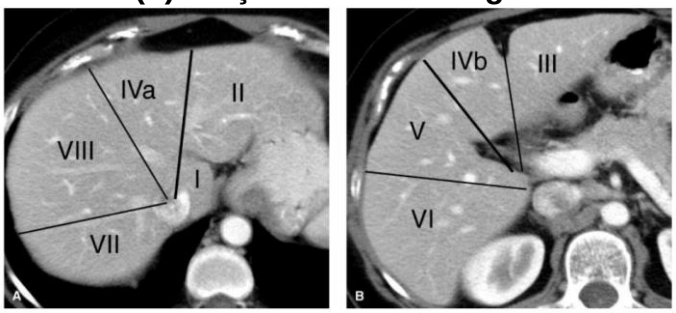

Fonte: (BRANT; HELMS, 2014).

O plano axial da veia porta esquerda separa o segmento IVa (Figura 4a), superiormente, do segmento IVb (Figura 4b), inferiormente, e o segmento II, superiormente, do segmento III, inferiormente, no lobo esquerdo. O plano axial da veia porta direita separa VIII e VII, superiormente, dos segmentos V e VI, inferiormente, no lobo direito. O lobo caudado (segmento I) se estende entre a fissura do ligamento venoso, anteriormente, e a veia cava inferior, posteriormente (BRANT; HELMS, 2014).

Tabela 2: Nomenclatura norte-americana e internacional para os segmentos hepáticos de Couinaud.

Norte-americana	Internacional	Número
Lobo caudado	Lobo caudado	**I**
Lobo esquerdo		
Segmento lateral	Subsegmento lateral superior esquerdo	**II**
Segmento medial	Subsegmento lateral inferior esquerdo	**III**
	Subsegmento medial esquerdo	**IVa**
Lobo direito		**IVb**
Segmento anterior	Subsegmento anteroinferior direito	**V**
	Subsegmento anterossuperior direito	**VIII**
Segmento posterior	Subsegmento posteroinferior direito	**VI**
	Subsegmento posterossuperior direito	**VII**

Fonte: Adaptado de (BRANT; HELMS, 2014).

Verificando a TC no ponto de visão do observador o órgão está localizado no lado esquerdo do abdômen superior e caracteriza como maior órgão (Figura 5) (MAHJOUB, 2012).

Os especialistas descrevem nos laudos médicos a localização e descobertas com base nos segmentos de Couinaud (Figura 5), sendo possível realizar o planejamento de ressecções de tumores ou hepatectomia (LYU, 2021).

Figura 5: Anatomia segmentar do Fígado. (a) Visão geral, (b) Lobo caudado, (c) Subsegmento lateral superior esquerdo, (d) Lateral inferior esquerdo, (e) Medial esquerdo, (f) Medial esquerdo inferior, (g) Anteroinferior direito, (h) Subsegmento anterossuperior direito, (i) Subsegmento póstero inferior direito e (j) Subsegmento póstero superior direito.

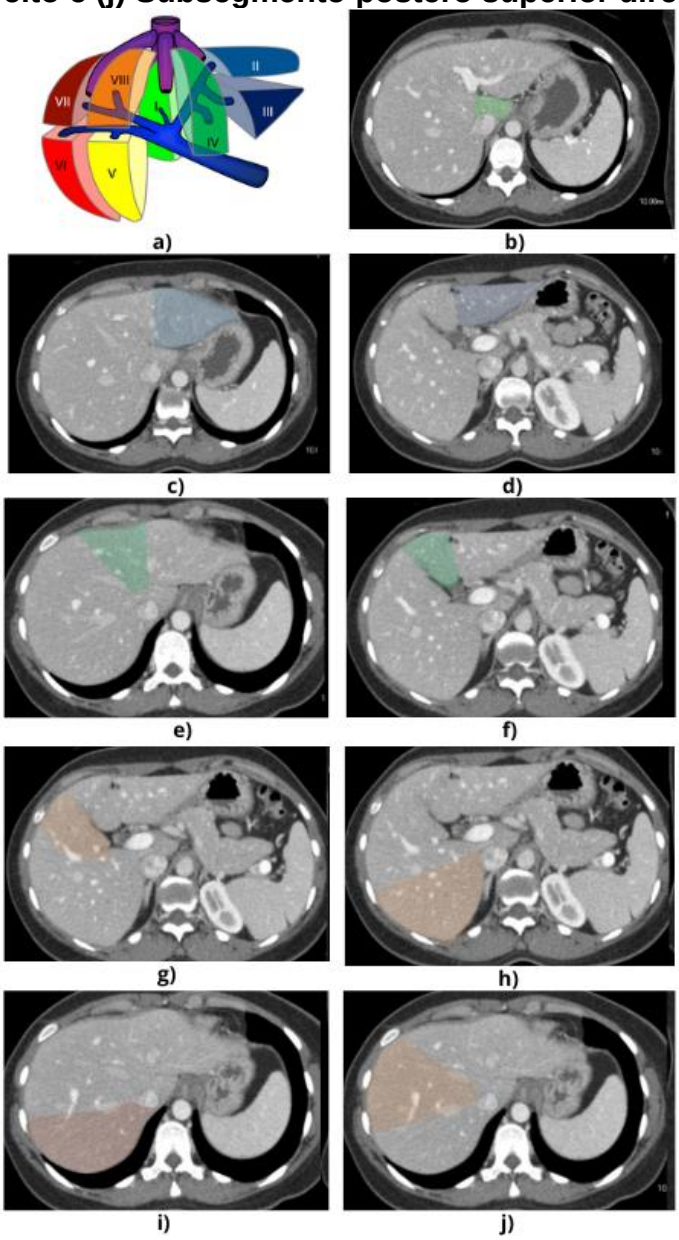

Fonte: Adaptado de (BASHIR, 2018).

3. PROCESSAMENTO DIGITAL DE IMAGENS

O campo do processamento digital de imagens se refere ao processamento de imagens digitais por um computador digital. Tem como principal objetivo de manipulação, onde envolve processos cuja entrada e saída são imagens, abordando extração de características e até o reconhecimento de objetos. Podem ser aplicados para atender diversas áreas, incluindo arte, fotografia, medicina, biologia, engenharia, entre outras (ACHARYA; RAY, 2005).

O processamento computacional de imagem pode ser classificado em três tipos: nível baixo, médio e alto. No processo de nível baixo envolve o pré-processamento, onde a entrada e a saída resultante são imagens, como exemplo, operações básicas de redução de ruído, ajuste de realce com contraste e aguçamento. Os níveis médios caracterizam pela entrada ser imagens, mas na saída normalmente estão atribuídos extraídos da imagem, como tarefas com segmentação de regiões e objetos a fim de aplicar classificação. Por fim, o processo de alto nível possui técnicas mais avançadas para extrair informações de uma imagem, como reconhecimento de objetos, aprendizado de máquina, redes neurais e reconhecimento de padrões (GONZALEZ, 2009).

A invenção, no início da década de 1970, da tomografia computadorizada, representa um dos eventos mais importantes na aplicação do processamento de imagens no diagnóstico médico. De 1960 até os dias de hoje, a área de processamento de imagens cresceu rapidamente. Além das aplicações na medicina e em programas espaciais, as técnicas de processamento digital de imagens, atualmente, são utilizadas em uma ampla variedade de aplicações (GONZALEZ, 2009).

Muitas técnicas básicas podem ser usadas ao trabalhar com imagens, incluindo: Ajuste de brilho e contraste, correção de cor, redimensionamento e filtragem. Essas estratégias simples são essenciais para garantir a qualidade visual e aprimorar os aspectos visuais básicos de suas imagens. Técnicas mais avançadas também estão disponíveis para tarefas mais complexas. Isso inclui detecção de borda, segmentação de imagem, reconhecimento de padrão, reconstrução 3D e muito mais. Embora várias técnicas estejam disponíveis na área de processamento digital de imagens, este estudo apenas descreve as estratégias utilizadas para alcançar os objetivos específicos do trabalho.

3.1. FUNDAMENTOS DA IMAGEM

Uma imagem pode ser definida como uma função bidimensional, *f(x, y),* em que *x* e *y* são coordenadas espaciais (plano), e a amplitude de *f* em qualquer par de coordenadas *(x, y)* chamamos de intensidade ou nível de cinza da imagem nesse ponto. Quando *x, y* e os valores de intensidade de f são quantidades finitas e discretas, chamamos de imagem digital (GONZALEZ, 2009).

No processo de digitalização, após a criação da imagem, convertemos a imagem analógica (onda de luz contínua) para uma imagem digital (*pixel* a *pixel*). A base de uma imagem se define como uma representação visual composta por *pixels* que representam pontos de luz usados para criar a imagem, que são processados por dispositivos eletrônicos e armazenados digitalmente (SCURI, 2002).

3.2. TRANSFORMAÇÕES DE INTENSIDADE

3.2.1. HOUNSFIELD

Hounsfield (HU) se caracteriza como uma unidade de medida usada em tomografia computadorizada aplicada à atenuação de tecidos no corpo humano em relação ao ar. Sendo assim, possibilitando distinguir diferentes tipos de tecidos de uma região de interesse com base na densidade radiológica (MOURÃO *et al*., 2009) (ANASTÁSIO, 2015).

A escala *Hounsfield* pode ser utilizada para diferenciar as atenuações produzidas pelos diversos *voxels* que compõem uma fatia irradiada. Essa escala tem a água como referência com o valor igual a 0H (zero *Hounsfield).* O material menos absorvente, o ar, está no nível máximo inferior da escala e tem valor de -1.000H (MOURÃO *et al*., 2009).

Os valores de atenuação para a escala HU são obtidos por meio da Equação (1):

$$HU_{(x,y)} = 1000\ x\ \frac{\mu_{x(x,y)} - \mu_a}{\mu a} \qquad (1)$$

onde $HU_{(x,y)}$ representa a imagem atenuada com *Hounsfield*, $\mu_{x(x,y)}$ significa o coeficiente de atenuação para o raio X do tecido, μa equivale ao coeficiente de atenuação linear da água (BUZUG, 2008) (CIERNIAK, 2011).

Assim, quanto mais espesso tecido, menor será a radiação para atravessá-lo. Em contrapartida, quanto maior a energia dos fótons da radiação incidente, maior sua capacidade de penetração (LOPES, 2016).

Os valores de atenuação da escala de HU são correlacionados entre valores da escala de cinza (Tabela 3), onde essas referências são padronizadas e utilizadas para calibração de tomógrafo (BRANT; HELMS, 2014).

Tabela 3: Valores de Hounsfield para tecidos presentes na literatura.

Tecido	Valor
Pulmões	-900 a -450
Gordura	-110 a -65
Rins	20 a 40
Pâncreas	30 a 50
Sangue	35 a 55
Sangue coagulado	70 a 80
Músculo	40 a 60
Fígado	50 a 75
Ossos porosos	100 a 200
Ossos corticais	250 a 900

Fonte: Adaptado de (BRANT; HELMS, 2014).

3.2.2. JANELAMENTO

O processo de Janelamento tem o objetivo de priorizar a visibilidade de uma região dentro do ajuste de escala de cinza. Se comporta como um recurso computacional que vai permitir ajustar a atenuação da região de interesse representado dentro de um intervalo de escala de cinzas, e na tomografia possui mais de 2000 valores de variação na atenuação. Assim, há três janelas básicas principais para distribuição dos níveis de cinza: a janela de pulmões, a janela de tecidos moles e a janela de tecidos ósseos (MOURÃO *et al*., 2009).

O método envolve a seleção de um intervalo específico de valores de *pixel* da imagem, que são mapeados para um intervalo de valores de cinza visíveis na tela do computador. A seleção de um intervalo apropriado de valores de *pixel* tem o

objetivo de maximizar e evidenciar o contraste entre as diferentes estruturas (SCURI, 2002).

Na Figura 6 exemplifica a aplicação do janelamento conforme intervalo com a região de interesse. Possível analisar o comportamento da imagem para escalas de cinza diferenciadas sobre a escala Hounsfield.

Figura 6: Aplicação do janelamento em diferentes distribuições de escalas. (a) janela para tecidos ósseos, (b) janela para tecidos moles e (c) janela para pulmões.

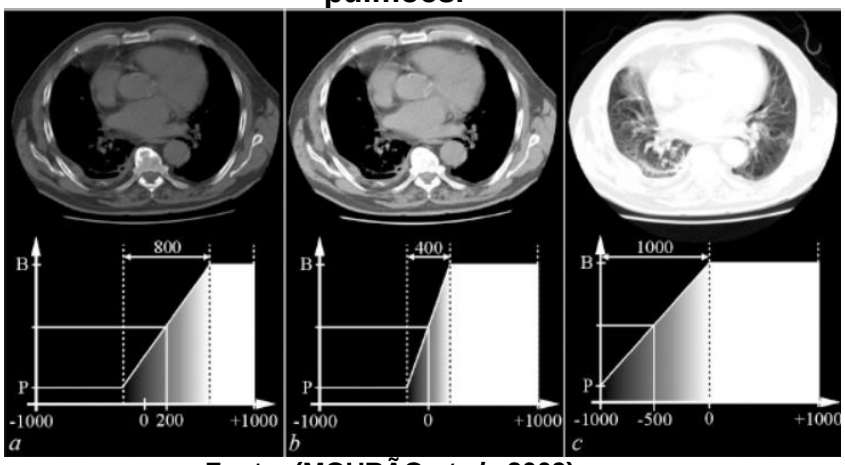

Fonte: (MOURÃO *et al.,* 2009).

3.3. RESTAURAÇÃO DA IMAGEM

3.3.1. FILTRAGEM ESPACIAL

A filtragem espacial pode ser utilizada para uma larga faixa de aplicações, principalmente para realce e nitidez de imagens. Essa técnica se baseia em uma máscara matemática que desliza *pixel* a *pixel* sobre a imagem cuja resposta calculada de acordo com a ordenação (classificação) dos *pixels* contidos na área da imagem coberta pelo filtro e substituindo o valor do *pixel* central pelo valor determinado de acordo com o resultado da classificação (GONZALEZ, 2009).

3.3.1.1. FILTRO MEDIANA

O filtro de mediana substitui o valor de um *pixel* pela mediana dos valores de intensidade na vizinhança desse *pixel*. Os filtros de mediana são bastante populares, porque, para certos tipos de ruído aleatório, proporcionam excelentes resultados na redução de ruído, com borramento consideravelmente menor do que

filtros lineares de suavização de tamanho similar (Figura 7). Para realizar a filtragem por mediana em um ponto de uma imagem, primeiro ordenamos os valores dos *pixels* da vizinhança, calculando a mediana e atribuindo o valor ao *pixel* correspondente na imagem filtrada (GONZALEZ, 2009).

Figura 7: Filtragem Mediana. (a) Imagem de placa de circuito com ruído e (b) Redução de ruído com filtro mediana 3x3.

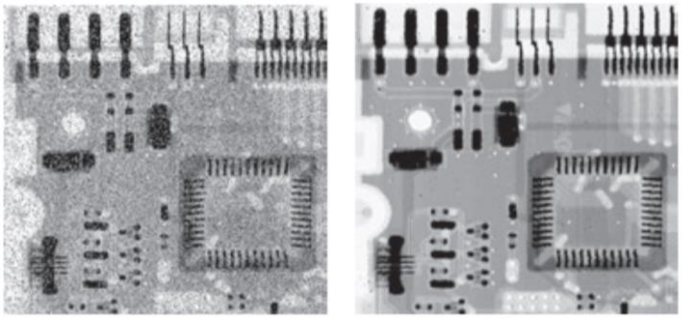

a) b)

Fonte: (GONZALEZ, 2009).

A filtragem utilizando a técnica da mediana obtém comportamento não linear, e tem aplicação útil para a finalidade de remover linhas ou *pixels* isolados, ao mesmo tempo que preserva a resolução espacial da imagem principalmente quando possui ruído binário (ACHARYA; RAY, 2005).

3.3.2. FILTROS DE REALCE E SUAVIZAÇÃO

Filtros para suavização de imagens são amplamente usados em processos de visão computacional, pois com as filtragens possibilita reduzir o ruído e suavizar as transições entre os *pixels* (GONZALEZ, 2009).

3.3.2.1. FILTRO DE DIFUSÃO ANISOTRÓPICO

Em 1990, Perona e Malik desenvolveram a Equação (2) para o filtro de difusão anisotrópico que preserva as bordas e detalhes da imagem, ao mesmo tempo que reduz o ruído e imperfeições (WEICKERT, 2001).

$$\frac{\partial l}{\partial t} = div(c(x,y,t)\nabla l(x,y,t) \quad (2)$$

onde *I(x,y,t)* simboliza a intensidade da imagem na posição *(x,y)* e no tempo *t*, enquanto *∇I(x,y,t)* representa o gradiente da imagem na posição *(x,y)* e tempo *t*, o

c(x,y,t) significa o coeficiente de difusão na posição *(x,y)* e tempo *t*, e por fim, *div()* o operador de divergência (WEICKERT, 2001).

Esse filtro leva em consideração as características importantes da imagem, mantendo a nitidez das bordas ao mesmo tempo que remove o ruído. Se torna muito útil a aplicabilidade em imagens médicas, pois na área da saúde possuem estruturas finas e as bordas precisam ser precisas para identificação de estruturas e diagnósticos confiáveis (WEICKERT, 2001).

3.3.3. FILTRAGEM DE MÍNIMO ERRO QUADRÁTICO MÉDIO

Filtro de Wiener em homenagem a N. Wiener (1942), o primeiro a propor esse conceito em 1942. O filtro também costuma ser chamado de filtro de mínimo erro quadrático médio ou filtro de mínimo erro quadrático (GONZALEZ, 2009).

O método se baseia em considerar imagens e ruído como variáveis aleatórias, com o objetivo de encontrar uma estimativa Im da imagem não corrompida Im, de forma que o erro quadrático médio entre eles seja minimizado (ANASTÁSIO, 2015). O filtro de Wiener pode ser calculado com base na Equação (3).

$$\mu = \frac{1}{MN} \sum_{n1,n2\ \epsilon n} Im(n1,n2)$$

$$\sigma^2 = \frac{1}{MN} \sum_{n1,n2\ \epsilon n} Im^2(n1,n2) - \mu^2 \qquad (3)$$

$$b(n1,n2) = \mu + \frac{\sigma^2 - v^2}{\sigma^2} (Im(n1,n2) - \mu$$

onde Im equivale a imagem a ser aplicado o filtro de Wiener, μ a média estimada ao redor do *pixel* da imagem Im, σ^2 variância estimada ao redor do *pixel* da imagem Im, a variância do ruído representada por v^2 e a vizinhança ao redor do *pixel* (MN) (ANASTÁSIO, 2015).

Figura 8: Resultado do filtro Wiener. (a) Imagem com ruído e (b) Filtro Wiener.

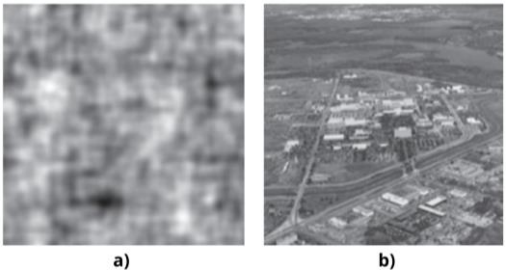

Fonte: (GONZALEZ, 2009).

O filtro adaptativo de Wiener ajusta a resposta com base nas propriedades aplicadas a ele, restaurando a imagem original que foi corrompida pelo ruído e tornando a qualidade mais nítida (Figura 8) (ANASTÁSIO, 2015).

3.4. SEGMENTAÇÃO DE IMAGENS

De acordo com Gonzalez (2009), a segmentação faz parte da etapa essencial do processamento digital de imagens, que envolve a subdivisão da imagem em regiões ou objetos constituintes. Cada segmento agrupado por um conjunto de *pixels* com características semelhantes com a vizinhança, formado a partir de regiões homogêneas na imagem, e cercado por regiões não homogêneas. No entanto, a segmentação se torna uma tarefa complexa, pois tenta imitar um processo cognitivo sofisticado de visão realizado pelo ser humano (GONZALEZ, 2009).

3.4.1. AGRUPAMENTO (CLUSTERING)

A Clusterização de Dados ou Análise de Agrupamentos representa uma técnica de mineração de dados através de aprendizado não supervisionado, para segmentar uma imagem em regiões de *k* grupos com características semelhantes, geralmente disjuntos denominados *clusters* ou agrupamentos (RIBEIRO, 2022).

A ideia básica utiliza elementos que componham um mesmo *cluster* devem apresentar alta similaridade, mas devem ser muito dissimilares de objetos de outros *clusters*, onde seus *pixels* são atribuídos e representados por um vetor (ACHARYA; RAY, 2005).

Possui importante van*tag*em no uso dessa técnica porque descreve de forma mais eficiente e eficaz as características peculiares de cada um dos grupos identificados. Isso fornece um maior entendimento do conjunto de dados original, além de possibilitar o desenvolvimento de esquemas de classificação para novos dados e descobrir correlações interessantes entre os atributos dos dados que não seriam facilmente visualizados sem o emprego de tais técnicas. Alternativamente, clusterização pode ser usada como uma etapa de pré-processamento para outros algoritmos, tais como caracterização e classificação, que trabalham nos *clusters* identificados (HRUSCHKA; EBECKEN, 2001).

Existem diferentes algoritmos de agrupamento, como o *k-means*, o *hierarchical clustering* e o DBSCAN, que são atualmente aplicados em imagens utilizando medidas de similaridade, como agrupamento de *pixels* e distância euclidiana. No âmbito deste trabalho foi aplicado a técnica de segmentação baseada no algoritmo de *k-means* a fim de minimizar a soma das distâncias quadráticas entre os objetos e seus centroides, conhecido como a soma dos quadrados das distâncias ou a soma dos erros ao quadrado. Após a execução do algoritmo, os objetos do conjunto de dados estarão agrupados em *K clusters*, cada um com um centroide representativo (Figura 9). O resultado final depende principalmente da configuração inicial e da quantidade de sequenciais que são testados (ACHARYA; RAY, 2005).

O algoritmo de *K-means* funciona em etapas, a primeira delas denominada de inicialização, onde o usuário especifica o número de *K* desejado. Então o algoritmo seleciona aleatoriamente *K* conjuntos de dados para serem os centroides iniciais da imagem. A fase seguinte tem a função de atribuição de cada objeto no conjunto de dados, de forma que são coletados os *pixels* mais próximos do centroide correspondente. Na terceira fase ocorre a atualização dos centroides de cada *cluster*, no qual são recalculados a partir da média de todos os objetos atribuídos àquele grupo. Por fim, a etapa de interação, onde as etapas segunda e terceira sequência são repetidas até que os *clusters* deixem de mudar ou o critério de parada seja atingido (RIBEIRO, 2022).

Figura 9: Exemplo de aplicação do algoritmo de agrupamento *K-means* para vários valores de K. (a) K = 2, (b) K = 3, (c) K = 10 e (d) Imagem Original.

(a) (b) (c) (d)

Fonte: Adaptado de (BISHOP, 2006).

4. ALGORITMO DE SEGMENTAÇÃO DO FÍGADO

Neste capítulo do trabalho, serão descritas as etapas realizadas para o desenvolvimento do algoritmo de segmentação do fígado com ênfase nos métodos e técnicas empregados para alcançar a visualização tridimensional do órgão

Para a modelagem da base foi utilizado o *software* MATLAB *(MATrix LABoratory)* na versão R2020a, pois possui uma ampla gama de ferramentas, bastante utilizada no processamento de imagens digitais, devido à capacidade de trabalhar com matrizes e vetores, aplicado nas áreas de engenharia, medicina, ciência da computação e visão computacional (MATLAB,2023).

Este estudo tem como propósito aplicar técnicas de processamento de imagens médicas em tomografias do abdome superior para extrair características relevantes e segmentar o fígado, visando à determinação do volume hepático e a visualização tridimensional da estrutura. Essa abordagem configura fundamental para o planejamento de procedimentos cirúrgicos, especialmente em casos de transplante de fígado, nos quais o conhecimento da localização e do volume hepático se faz necessário para intervenções mais eficazes.

A Figura 10 ilustra o diagrama de bloco da estratégia aplicada no algoritmo, onde foi desenvolvido em três principais etapas: 1) Pré-processamento: aplicação de técnicas de remoção de ruídos, realce de bordas, e corrigir iluminação e contraste, visando melhorar a qualidade da imagem, e tornar mais fácil a identificação da região em estudo; 2) Processamento: utilização da segmentação para separar as regiões de interesse, por meio de agrupamento de *pixels* em segmentos com características semelhantes, sem a necessidade de um conjunto de dados pré-treinados; 3) Pós-processamento: automatização da etapa de extração de características como: tamanho (área) e formas, possibilitando o cálculo da precisão do resultado

Figura 10: Diagrama de bloco com os métodos utilizados no processo.

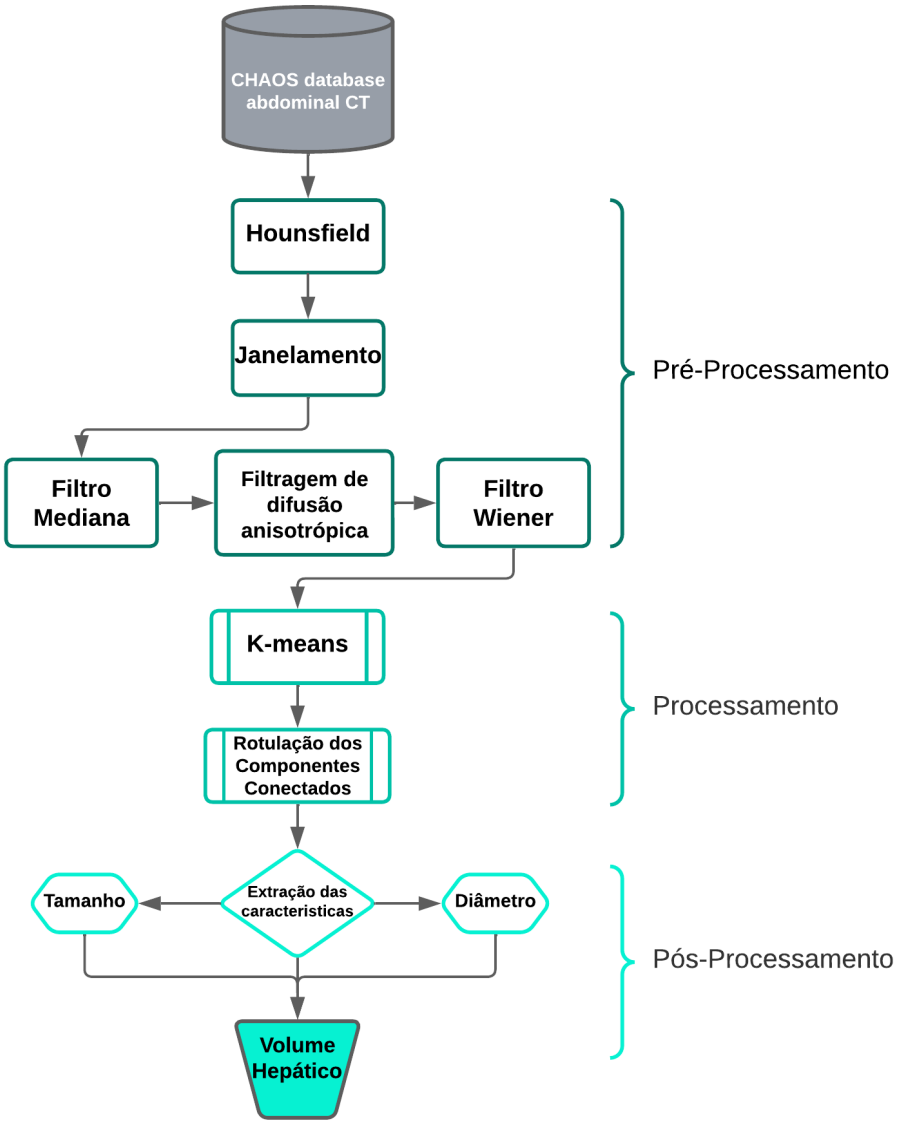

Fonte: Autora.

4.1. BASE DE DADOS

No contexto deste trabalho as imagens de tomografia foram coletadas e fornecidos pelo banco de dado *Combined (CT-MR) Healthy Abdominal Organ Segmentation* (CHAOS), um desafio com a finalidade de realizar a Segmentação do fígado a partir de conjuntos de dados de tomografia computadorizada, que são adquiridos na fase portal após a injeção do agente de contraste para pré-avaliação de doadores (KAVUR, 2019).

As imagens foram extraídas do Departamento de Radiologia, no Hospital *University Dokuz Eylul* no Peru, coletadas aleatoriamente do PACS do hospital, e

todos os exames estão no formato DICOM e de possíveis doadores para transplante hepático, ou seja, são fígados saudáveis, sem doenças ou lesões (KAVUR, 2020).

De acordo com Kavur *et al.* (2021), os principais desafios nos dados contidos no banco de imagens CHAOS são citados como: os intervalos de valores de Hounsfield nas imagens são semelhantes aos órgãos adjacentes. Os limites entre cada estrutura não são bem definidos, além disso, na base possui exames com variação de contraste para o mesmo tecido, devido ao meio de contraste aplicado, como exemplo, vasos sanguíneos do fígado menos acentuados. E por fim, diferenças relevantes no formato das estruturas anatômicas entre pacientes, apresentando um total de 4,15% do banco de dados englobando formatos de fígado atípicos, onde o tamanho ou a sua orientação estão fora do padrão (KAVUR, 2020).

Para obtenção dos exames foram usados três tomógrafos diferentes, *Philips SecuraCT* com 16 detectores e um *Philips* Mx8000 CT com 64 detectores e *Toshiba AquilionOne* com 320 detectores, ambos configurados com a opção de TC em formato espiral. Todos os pacientes estão na mesma orientação para realização do procedimento em todo o conjunto de dados. O banco de dados contém imagens DICOM com resolução de 16 *bits*, com tamanho de 512x512 *pixel*s na largura e na altura. O espaçamento entre os *pixels* de 0,7 a 0,8 mm, e a distância entre os cortes (ISD) varia entre 3 e 3,2 mm (KAVUR, 2019).

Todos os dados de TC possuem em média 116 fatias, variando de no mínimo 81 *slices* ao no máximo 197 fatias por paciente, totalizando 2317 imagens (Tabela 4).

Tabela 4: Quantidade de Exames de TC abdominal contemplados na base de dados.

Exames	Quantidade de Imagens
1	93
2	81
3	95
4	82
5	97
6	103
7	93
8	89

9	106
10	90
11	170
12	101
13	176
14	91
15	118
16	106
17	178
18	102
19	149
20	197
Total	2317
Média	115,85

Fonte: Autora.

4.2. PRÉ-PROCESSAMENTO

A primeira etapa do pré-processamento inicia com a leitura de todas as fatias de cada exame no formato *.dcm*. Após, ocorre o estudo das informações contidas nas *Tags* do DICOM, principalmente ao que se refere aos parâmetros de aquisição, em seguida foi aplicado a técnica de Hounsfield e janelamento para proporcionar uma melhor visualização do tipo de estrutura examinada. Posteriormente, ocorre aplicação de combinações de filtros para realçar as bordas do fígado e reduzir os ruídos causados pelos artefatos na realização do exame.

4.2.1. HOUNSFIELD

Nessa etapa a aplicação do Hounsfield na fatia original da TC de abdômen tem o objetivo de pré-processamento para permitir evidenciar os valores relacionados ao fígado e tecidos moles. Logo, com base na densidade radiológica podemos omitir os tecidos não relacionados, como ossos e ar.

Em imagens de tomografia computadorizada, os valores de *pixel* são inicialmente representados em uma escala de unidades de tom (unidades arbitrárias). Para converter esses valores em unidades de Hounsfield (que são calibradas para representar a atenuação dos tecidos), o "*Rescale Slope*" e o "*Rescale Intercept*", que estão presentes nas *Tags* DICOM (0028,1053) e

(0028,1052), respectivamente, são usados para aplicar uma transformação linear aos valores de *pixel* originais. O *"Rescale Intercept*" adicionado ao valor do *pixel* multiplicado pelo "*Rescale Slope*" para obter o valor final do *pixel* na escala desejada.

Em cada fatia foi coletado o *Rescale Intercept* e *Rescale Slope* por meio da leitura das informações presentes dentro de cada fatia da imagem DICOM, e aplicado o HU de acordo com a Equação (4):

$$HU(s,j,i) = I(s,j,i) * Rslope(i) + RIntercept(i) \quad (4)$$

onde $HU(s,j,i)$ representa o *slice* resultante da atenuação, $I(s,j,i)$ a fatia original, $Rslope(i)$ e $RIntercept(i)$ que equivale ao ajuste de inclinação aplicado aos valores de *pixels*, e o ajuste linear aplicado aos valores de *pixel* respectivamente (ANASTÁSIO, 2015).

A resposta conforme mostrada na Figura 11, se refere ao exame 11 aplicado na fatia de número 52. Dessa forma, se torna evidente a diferença entre a imagem original e atenuação aplicada.

Figura 11: Exemplo de fatia Nº 54 do exame 11. (a) Fatia de TC sem nenhum processamento e (b) Imagem após aplicação HU.

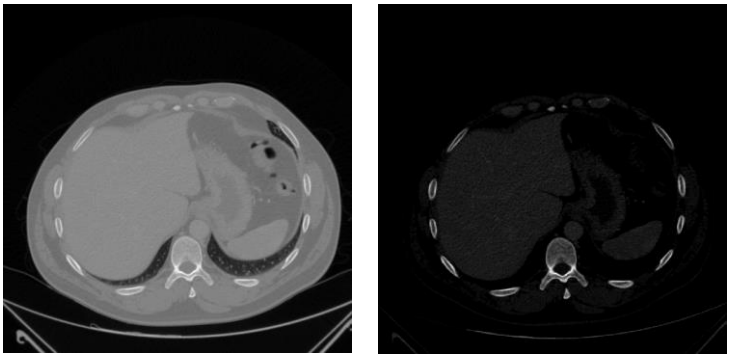

a) **b)**

Fonte: Autora.

4.2.2. JANELAMENTO

A extração do fígado pode ser difícil porque o tecido hepático tem uma atenuação semelhante a outras estruturas do abdômen, como músculos, pâncreas e gordura. Nesse caso, a técnica de janelamento foi usada no presente estudo para as imagens de exames dos pacientes, categorizando dentro de um intervalo a

janela de destruição de tecidos moles. Onde são selecionados valores de *pixels* que correspondem à escala de Hu que se aproxima do fígado.

O processo envolve a seleção de um intervalo específico de valores de *pixel* da imagem, que são mapeados para um intervalo de valores de cinza visíveis na tela do computador. A seleção de um intervalo apropriado de valores tem a finalidade de maximizar o contraste entre as diferentes estruturas. Então nessa fase foi considerado os valores presentes nas *Tags* (0028,1050) e (0028,1051) que são do inglês *Window Center* (WC) e *Window Width* (WW) respectivamente, para aplicação do janelamento, seguindo a Equação (5):

$$PixelSaida = \begin{cases} 0, & se\ PixelEntrada\ \leq\ WC - \frac{WW}{2} \\ 255, & se\ PixelEntrada\ \geq WC + \frac{WW}{2} \\ PixelEntrada, & caso\ contrário \end{cases} \quad (5)$$

onde o $PixelSaida$ denomina valor do *pixel* de saúde resultando do janelamento, $PixelEntrada$ representa o valor de entrada na fatia, WC o valor do centro da janela da fatia e WW o valor do tamanho da janela da fatia (ANASTÁSIO, 2015).

Se o resultado for menor igual ao janelamento, o *pixel* será substituído por valor 0, representando a cor preta, e caso o valor do *pixel* analisado seja maior ou igual, substitui por 255, que representa a cor branca. Caso contrário, se mantém o *pixel* original.

Após aplicação do processo (Figura 12), resultou em uma imagem com contraste maior no fígado comparadas as estruturas circundantes, facilitando a visualização da região de interesse.

Figura 12: Imagem com janelamento.

Fonte: Autora.

4.2.3. FILTRO MEDIANA

Para aquisição da filtragem mediana, foi aplicado uma janela padrão que percorre *pixel* a *pixel* na imagem, calculando a mediana dos valores dentro da máscara e substituindo o valor central da janela analisada pelo valor calculado na mediana. Esse filtro foi usado para reduzir ruídos, melhorar a homogeneidade das imagens, e minimizar a variação nos níveis de intensidade dos *pixels*, por ser de fácil implementação em imagens de grande tamanho, como no caso das tomografias de abdômen superior (Figura 13).

Figura 13: Resultado da fatia depois do filtro mediana.

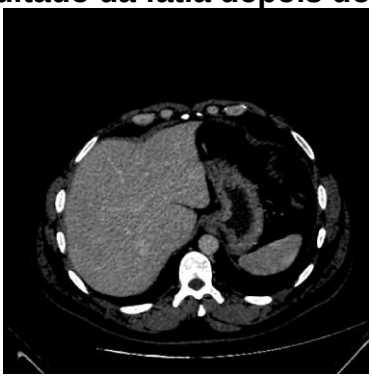

Fonte: Autora.

4.2.4 FILTRO DE DIFUSÃO ANSIOTRÓPICO

A filtragem difusa foi aplicada para suavizar o ruído e preservar as bordas do fígado. Assim, ajustou a qualidade visual das fatias dos exames (Figura 14), sem causar perda significativa de informações e detalhes no processamento preservando suas características e suavizando as bordas.

Figura 14: Resultado da fatia depois da filtragem difusa.

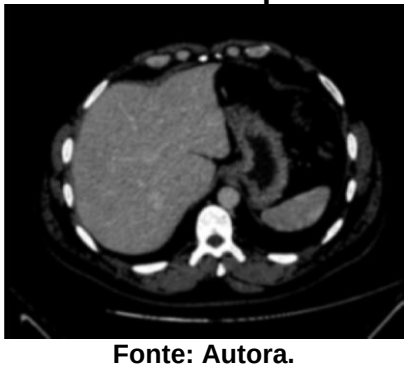

Fonte: Autora.

4.2.5 FILTRO DE WIENER

O filtro Wiener foi projetado para minimizar o erro quadrático médio entre o sinal original e a imagem reconstruída. Nesse processo a função de transferência usa a transformada de Fourier da imagem para calcular o espectro de potência e aplica também a degradação e análise do ruído para restauração.

A filtragem foi aplicada nessa etapa de pré-processamento para adequar a qualidade da imagem e não prejudicar as bordas. No grande volume de imagens presente no banco de dados o tamanho da máscara que melhor se comportou e não degradou as estruturas foi [5X5] (Figura 15).

Figura 15: *Slice* resultante depois da Filtragem de Wiener.

Fonte: Autora.

4.3. PROCESSAMENTO

Na etapa do processamento ocorre a segmentação das regiões para extrair o órgão de interesse. A técnica de segmentação trabalhada foi o algoritmo de *K-mens,* e em seguida retirados os *pixels* desconexos para obter maior precisão na segmentação final do fígado, evitando assim que ocorram interferências no volume hepático. Além disso, esses artefatos isolados podem levar a falsos positivos ou negativos no algoritmo final, visto que não se referem a região hepática.

4.3.1. SEGMENTAÇÃO *K-MEANS*

O Algoritmo de *k-means* aplicado divide os *pixels* em *k* grupos, sendo *k* um número definido para o projeto com *k* = 5, com finalidade de separar as regiões dos ossos, vasos sanguíneos, *background* (fundo), fígado e outros órgãos. O algoritmo

começa selecionando aleatoriamente *k pixels* da imagem como centroides dos *clusters*, e então atribui cada *pixel* da imagem ao *cluster* cujo centroide está mais próximo. Depois, recalcula os centroides dos *clusters* e repete o processo de atribuição de *pixels* até que os *clusters* não mudem mais.

Após a segmentação do algoritmo, as regiões encontradas na fatia ficaram agrupadas de acordo com as propriedades semelhantes que compartilham (Figura 16). Além disso, foi identificado a necessidade de analisar os padrões relevantes e extrair no pós-processamento as características de tamanho, forma ou intensidade dos *pixels*.

Figura 16: Fatias do exame 11 depois da segmentação *K-means* com 5 *Clustering*. (a) Fatia de TC do nº 12, (b) Fatia de TC do nº 52, (c) Fatia de TC do nº 115 e (d) Fatia de TC do nº 137.

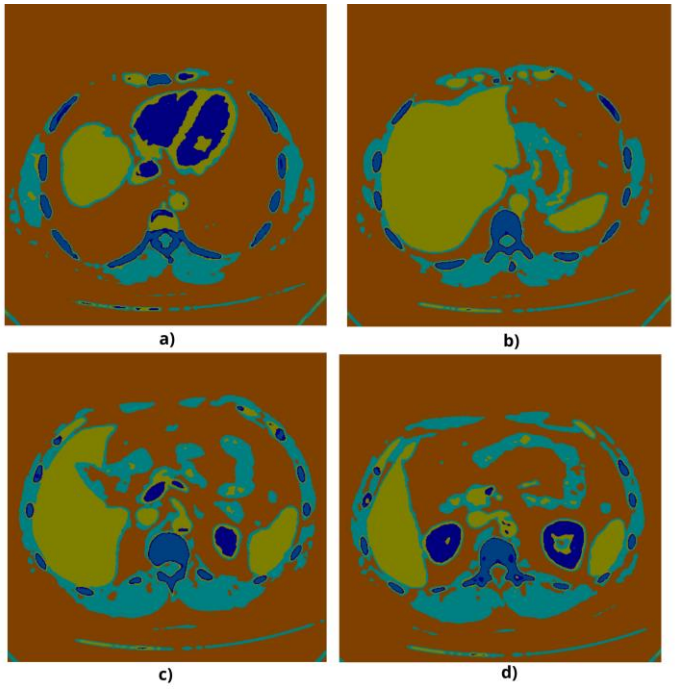

Fonte: Autora.

4.3.1.1. ROTULAÇÃO DOS COMPONENTES CONECTADOS

Depois da segmentação de *k-means*, foi analisada a conectividade existente nas imagens, e identificado que mesmo depois do agrupamento, ainda permaneceu artefatos (*pixels* desconexos) que podem interferir significativamente na volumetria.

Como proposta de minimizar a situação mencionada, no algoritmo proposto foi aplicado o processo de identificar e rotular cada região por meio da conectividade definida na função, chamada conectividade-8, para que todos os

pixels vizinhos adjacentes, nas oito direções possíveis incluindo as diagonais são considerados *pixels* conectados.

O objetivo da técnica de rotulagem de componentes conectados consiste em atribuir em toda a imagem rótulos distintos a cada *pixel* no mesmo componente conectado até que não haja mais nenhum objeto não rotulado na imagem (ACHARYA; RAY, 2005).

Dessa forma, os elementos na imagem que estavam desconexos foram removidos, podendo assim identificar visualmente a região que representa o fígado (Figura 17).

Figura 17: Fatia de um paciente depois da rotulação dos componentes conectados.

Fonte: Autora.

4.4. PÓS-PROCESSAMENTO

Na etapa final, foi realizado o pós-processamento para remover regiões indesejadas deixadas nas imagens que compartilham características semelhantes, como o baço com densidade semelhante e localização próxima ao fígado. Além disso, o tecido adiposo presente próximo ao fígado pode dificultar a identificação precisa das estruturas e bordas. O pós-processamento, portanto, desempenha um papel importante na melhoria da imagem resultante.

4.4.1. EXTRAÇÃO DO FÍGADO

Com o propósito de extração do fígado para cálculo volumétrico, foi possível analisar o padrão característico do órgão referente a sua localização e tamanho, assim extrair o fígado usando propriedades definidas.

Vale ressaltar, que o seu tamanho tem variação em conjunto com sua rotatividade de acordo com a varredura do tomógrafo, ou seja, normalmente o fígado se inicia na região medial e estende em direção ao quadrante superior direito do abdômen. Para esse critério foi dividido todo o exame do paciente em dois grupos (partes), onde a primeira parte representada pelo fígado foi extraído baseado no atributo do tamanho, no qual a maior área foi extraída e denominada como fígado (Figura 18).

Figura 18: Extração da primeira parte do fígado em função do atributo tamanho.

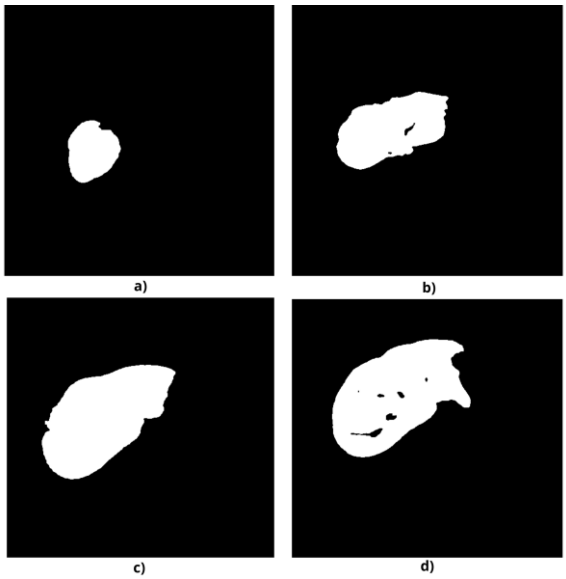

Fonte: Autora.

A segunda metade das imagens (Grupo 2), foi aplicado a filtragem com base na propriedade do diâmetro equivalente, ou seja, apenas objetos com diâmetro equivalente são mantidos na imagem resultante e são denominados como pertencentes ao fígado (Figura 19).

A função percorreu todos os objetos da imagem, calculou seu diâmetro equivalente de cada região existente e comparou com o valor de limite definido igual a 1. Vale ressaltar, que no segundo grupo as fatias iniciam com a região do fígado maior e finalizam com a menor parte do órgão.

Assim sendo, a extração do fígado foi realizada nos 20 exames de tomografia, e permitiu a obtenção de uma máscara binária do fígado para cada fatia.

Figura 19: Extração da segunda parte do fígado em função do atributo do diâmetro equivalente.

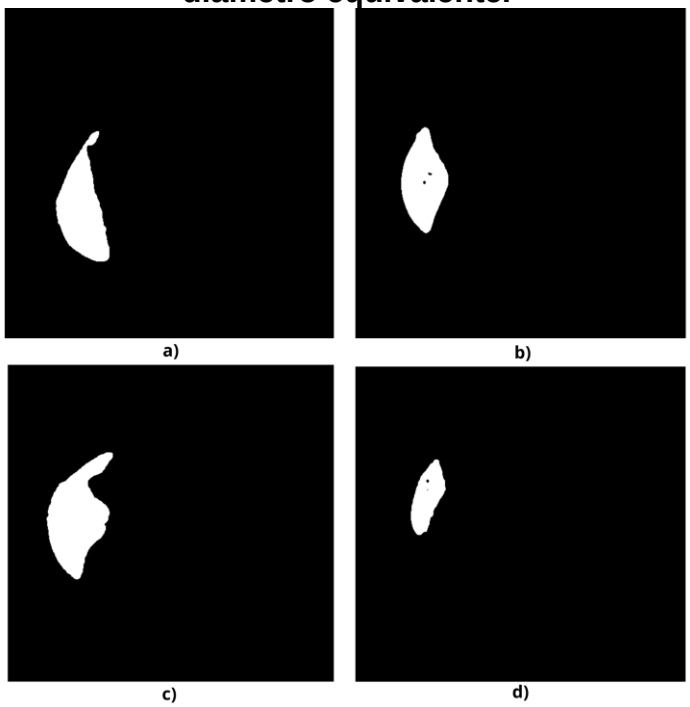

Fonte: Autora.

5. RESULTADOS E DISCUSSÕES

Neste capítulo do trabalho serão apresentados os resultados e discussões obtidos por meio da aplicação das técnicas propostas para segmentação do fígado. Os resultados e as métricas representam o desempenho da estratégia abordada. Foram descritas as análises estatísticas e interpretações dos resultados, explorando as aplicabilidades na área médica.

Na base de dados além dos 20 exames de possíveis doadores saudáveis para TH, que compreende as 2317 imagens contidas na base, possui também máscaras modelo do fígado viabilizando realizar o cálculo do volume hepático e metrificação dos resultados, permitindo comparações visuais, taxa de acerto, erro quadrático médio, coeficiente de similaridade e diferença relativa de volume entre as imagens de referência fornecidas e as imagens resultantes dos métodos descritos.

Quatro métricas foram usadas neste trabalho para avaliar o desempenho, em específico o Coeficiente Sørensen–Dice e Diferença relativa de volume absoluto (RAVD), por se tratar de dois parâmetros obrigatórios para avaliação do algoritmo no desafio CHAOS proposto na Base de Dados.

5.1. RESULTADOS DO ALGORITMO DE SEGMENTAÇÃO DO FÍGADO

As imagens testadas no algoritmo de segmentação são observadas a seguir. Na Figura 20 foi ilustradas as imagens referentes ao exame do paciente 11, com 170 fatias no total, e foi selecionado 9 *slices*, para exemplificar o comportamento do órgão conforme varredura do equipamento na realização do exame. A região segmentada foi adicionada a imagem original da tomografia a fim de evidenciar o fígado e sua variação de tamanho.

Os resultados mostram que foi possível segmentar fatias pequenas do fígado como também regiões maiores, fato importante, uma vez que a segmentação precisa e abrangente de um órgão que varia o tamanho exige maior complexidade, e demonstrou eficácia fundamental para a etapa posterior na geração da volumetria hepática.

Para a aplicação do algoritmo no Exame 11 a complexidade computacional foi calculada em uma máquina com processamento Intel i5, com 8GB de RAM e sistema operacional de 64 *bits*, resultando um tempo total de 3 minutos e 9

segundos para execução de todo processamento, desde a etapa de pré-processamento até a fase final de pós-processamento, com total de 170 *slices* processados. Apenas a fase de segmentação com *K-means* ocorreu no tempo de 16,6 segundos. Esse tempo pode variar de acordo com a quantidade de fatias para cada exame**.**

Figura 20: Ilustração das fatias originais do exame 11 de TC com a segmentação automática do fígado destacada na coloração vermelha.

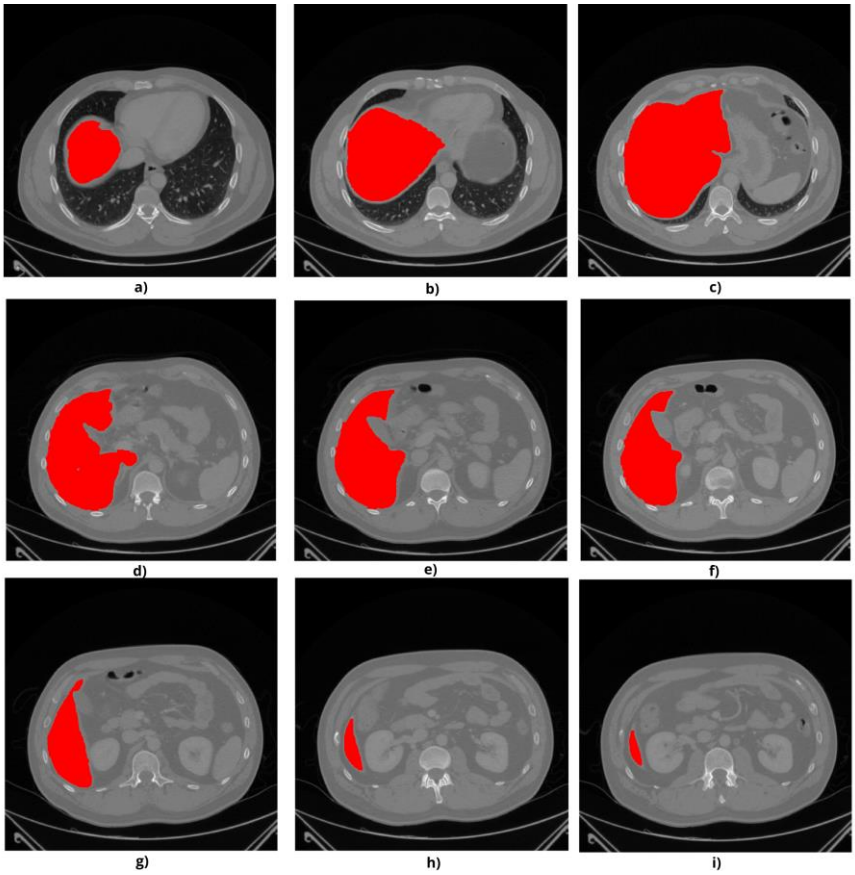

Fonte: Autora.

O diagrama de bloco fornece uma representação visual com a sequência lógica dos passos de todas as etapas aplicadas com seus respectivos resultados coletados nesta pesquisa, desde a imagem bruta até o fígado segmentado em 3D e seu volume (Figura 21). Para o cálculo do volume total foi realizado o volume de cada fatia contida no banco de dados da máscara e as imagens resultantes da segmentação automática (Tabela 5).

Figura 21: Diagrama de bloco com os resultados do exame 11.

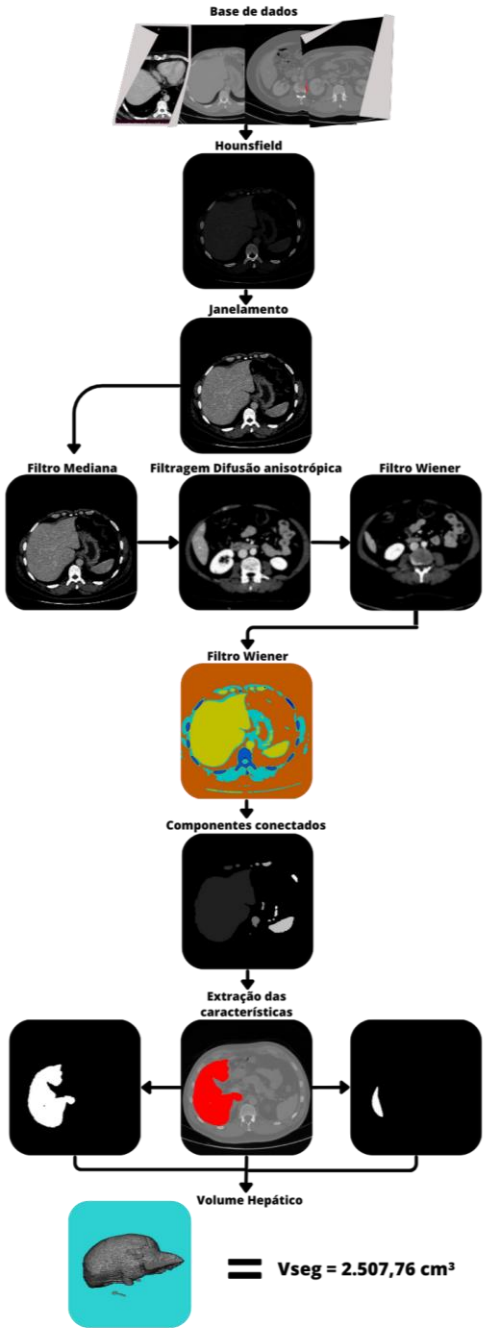

Fonte: Autora.

Tabela 5: Exemplos de volume de fatias do Exame 11

Exame	*Slice*	Volume Fatia referência (cm³)	Volume Fatia Segmentação automática (cm³)
11	17	12,7445656	10,6045849
11	18	13,2836626	11,3733841
11	19	13,8274474	11,9593591
11	20	14,3274794	12,4976748
11	21	14,9728332	13,0133328
11	22	15,5314627	13,5172713
11	23	16,3260448	14,0407423

Fonte: Autora.

O segundo exemplo, apresentado nas Figura 22 e Figura 23, diz respeito ao exame do paciente 12, com 101 *slices*. Nesta análise o algoritmo identificou nas regiões dos vasos sanguíneos a ocorrência da perda de *pixels,* conforme indicado nas setas em amarelo (Figura 22).

Figura 22: Ilustração das fatias originais do exame 12 de TC com a segmentação automática do fígado destacada em coloração vermelha.

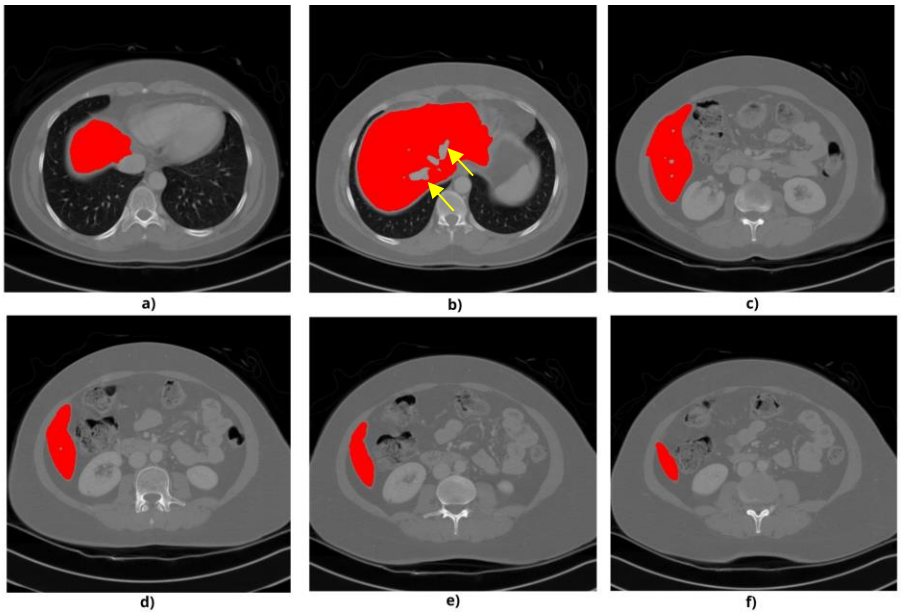

Fonte: Autora.

O tempo de processamento no Exame foi de 2 minutos e 46 segundos de duração, desde a etapa de pré-processamento até a fase final de pós-processamento, com a imagem binária do fígado com total de 101 *slices* processados. Em seguida foi calculado o volume de cada fatia como exemplificado na Tabela 6.

Tabela 6: Exemplos de volume de fatias do Exame 12

Exame	*Slice*	Volume Fatia referência (cm^3)	Volume Fatia Segmentação automática (cm^3)
12	17	20,7443808	22,3307073
12	18	21,1433112	20,9604681
12	19	21,5357373	22,0755942
12	20	21,6195705	24,5400012
12	21	21,774951	22,4015319
12	22	21,6080073	22,1037795
12	23	21,5357373	22,0582494

Fonte: Autora.

Figura 23: Diagrama de bloco com os resultados do exame 12.

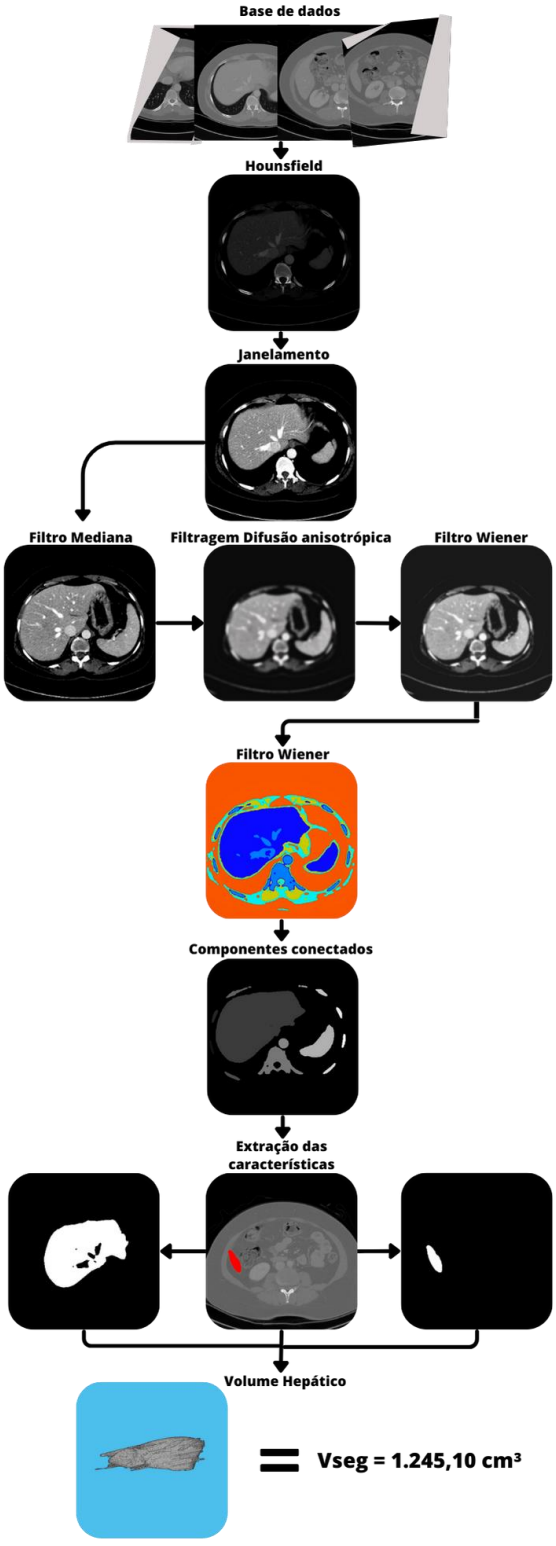

Fonte: Autora.

5.2. COMPARAÇÃO ENTRE A MÁSCARA MODELO E A SEGMENTAÇÃO PROPOSTA

Analisando a imagem segmentada de forma automática em comparação com as imagens de referência fornecidas pela base (Figura 24), foi possível verificar que as bordas do fígado acabaram desconsiderando alguns *pixel*s, não ficando precisas com exatidão, entretanto, se assemelham bastante às características e variações anatômicas do fígado, e nenhuma parte significativa do fígado foi omitida.

Na coluna I (Figura 24) foram apresentadas fatias da segmentação automática, e na coluna II (Figura 24) ilustra a mesma fatia referente a máscara modelo fornecida pela base de dados.

Figura 24: Fatias paciente 11. (a) e (b) Fatia 12, (c) e (d) Fatia 52, (e) e (f) Fatia 115, e (g) e (h) Fatia 137.

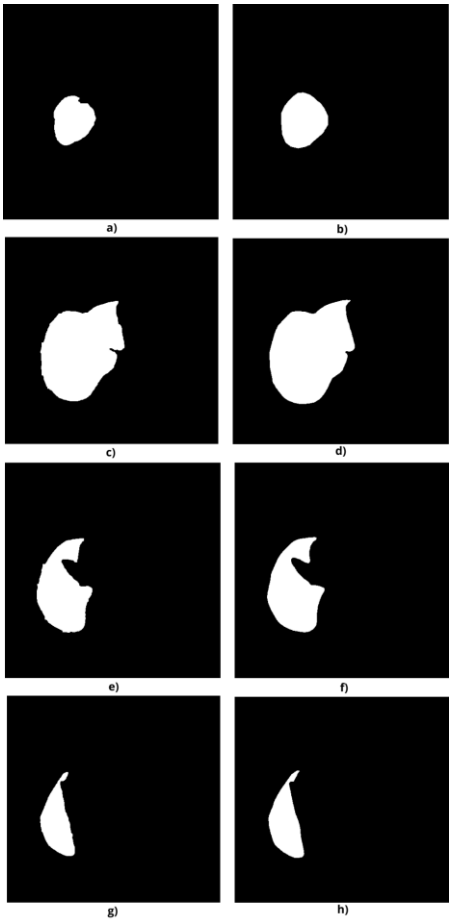

Fonte: Autora.

5.2.1. VOLUMETRIA HEPÁTICA

Para cálculo da volumetria hepática, baseada na Equação (6), foi coletado todas as fatias segmentadas do exame, em seguida realizado o somatório da quantidade de *pixel* diferentes de zero em cada imagem binária do exame. Com esse somatório temos a área do fígado em cada fatia, logo multiplicamos essa área pela dimensão do *pixel*, onde essa informação foi fornecida na *Tag* DICOM (0028,0020), *Pixel Spacing*, que representa em milímetros o espalhamento físico do *pixel* em imagens médicas. Em seguida, multiplicamos pelo *Spiral Pich Factor*, presente na *Tag* (0018,9311), que descreve a relação entre o avanço da mesa e a espessura do corte durante a aquisição do exame. Feito esse processo, o volume contido em cada fatia foi calculado por:

$$VFat = ImgS * PS * SPF \tag{6}$$

onde VFat simboliza Volume da fatia, *ImgS* a Imagem da fatia segmentada do fígado, *PS* representa a *tag Pixel Spacing* e por fim, *Spiral Pitch Factor* (SPF), espaçamento entre o avanço da mesa e a espessura de cada corte (ANASTÁSIO, 2015).

Ao final do primeiro cálculo, seguimos para obter o volume total do fígado da máscara de referência e o volume total da segmentação automática. Assim, foi aplicado o somatório dos volumes individuais de cada fatias, que compõem o exame do paciente, dado pela Equação (7) (ANASTÁSIO, 2015).

$$VTot = \sum VFat \tag{7}$$

onde Vtot representa o volume total do fígado e $\sum VFat$ composto pelo somatório do volume de cada fatia daquele exame. O volume total calculado em milímetros cúbicos, e em seguida convertidos em centímetros cúbicos para facilitar a análise dos resultados (ANASTÁSIO, 2015).

O cálculo do volume do fígado desempenha o principal objetivo do trabalho, pois fornece informações importantes para o especialista, com relação a saúde hepática, doenças, identificação de acúmulo de gordura, como também planejamento cirúrgico na seleção do doador ou avaliação de enxertos. Os resultados do volume total para cada paciente, são exibidos na Tabela 7.

Tabela 7: Volumes calculados com as imagens modelos fornecidas na base e volume calculados pelo algoritmo proposto no trabalho.

Exames	Quantidade de Imagens	Volume referência (cm^3)	Volume Segmentação automática (cm^3)
1	93	1.429,80	1.508,09
2	81	899,68	930,92
3	95	1.645,73	1.612,80
4	82	1.633,39	2.473,99
5	97	1.387,87	1.471,26
6	103	1.459,92	1.537,09
7	93	1.147,10	1.316,53
8	89	1.389,05	1.577,78
9	106	1.643,61	1.752,55
10	90	1.360,55	1.562,76
11	170	2.650,38	2.507,76
12	101	1.205,56	1.245,10
13	176	2.279,44	2.319,81
14	91	1.214,87	1.420,16
15	118	2.343,87	2.615,78
16	106	1.533,57	1.350,22
17	178	2.532,99	2.924,29
18	102	1.288,77	1.474,44
19	149	1.659,71	2.159,07
20	197	2.104,50	2.332,22
Média	**115,85**	**1.640,52**	**1.804,73**

Fonte: Autora

A média de volume hepático dos exames da base de dados, podem ser utilizados como referência e comparação para pacientes saudáveis. No estudo obteve uma diferença entre o volume referência e volume da segmentação automática relativamente pequena. Para uma análise visual (Figura 25) a representação da segmentação completa com base nos exames 11, 12, 13, 2 e 1 foi apresentada em três dimensões, tanto para a máscara, como para as imagens segmentadas na pesquisa.

Para obter a visualização 3D do fígado foi criado uma matriz 3D importando cada fatia binária da máscara modelo da base de dados em sua respectiva ordem. Com a matriz completa, foi importada no *Volume Viewer,* por meio da interpolação tridimensional uma representação contínua do fígado no espaço 3D. Para melhor análise visual foi posicionado o fígado na orientação anatômica. O mesmo processo descrito foi aplicado às fatias binárias resultantes da segmentação com o algoritmo proposto (Figura 25).

Foi observado resultados robustos, mediante variações mínimas a artefatos, onde normalmente, o baço e o estômago foram mal segmentados por alguns algoritmos descritos na literatura, devido a intensidade semelhantes ao fígado.

Figura 25: Visualização do fígado em 3D. (a) e (b) Fígado em 3D do exame 11, (c) e (d) Fígado em 3D do exame 12, (e) e (f) Fígado em 3D do exame 13, (g) e (h) Fígado em 3D do exame 2 e (i) e (j) Fígado em 3D do exame 1.

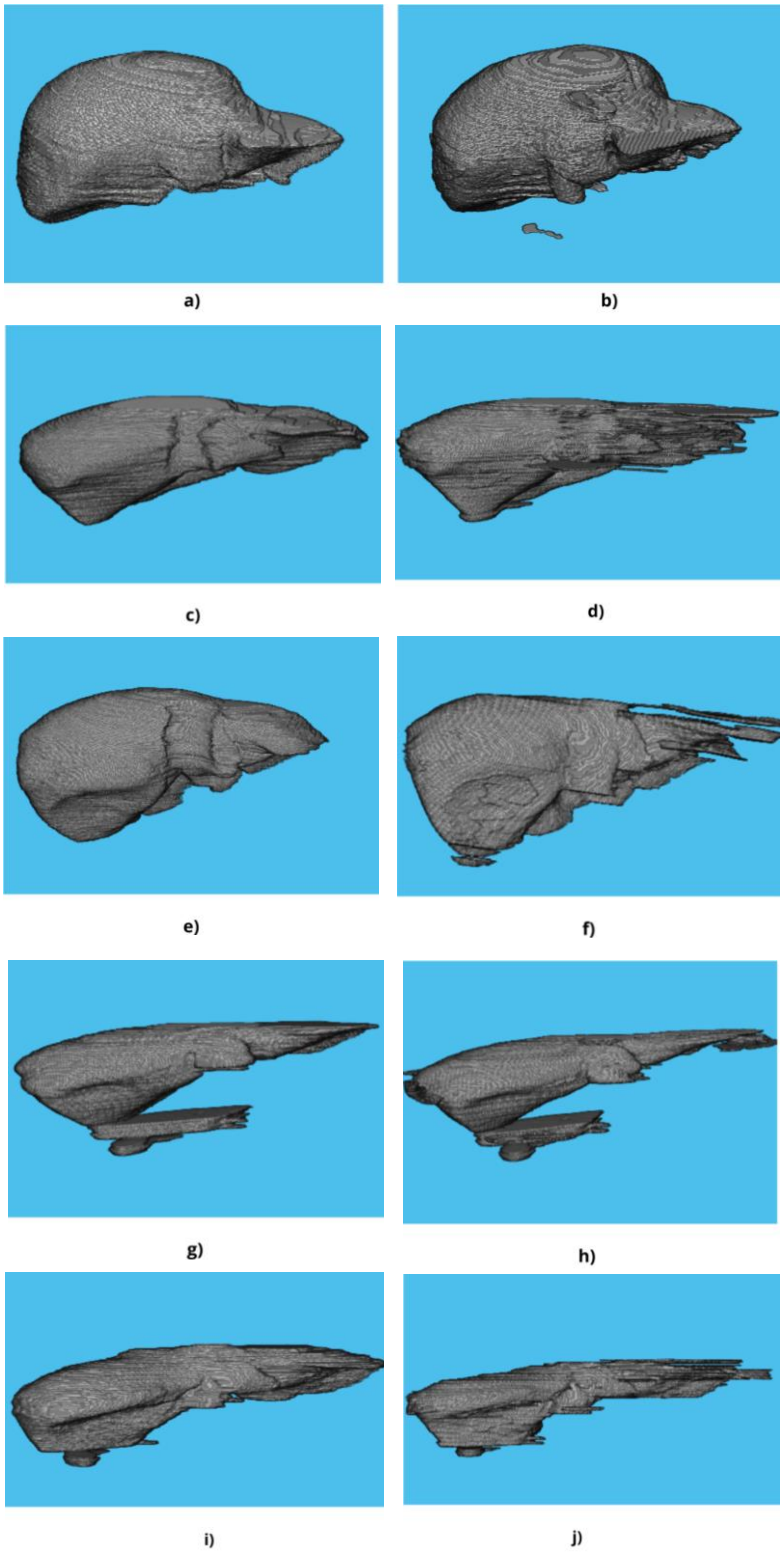

Fonte: Autora.

5.2.2. TAXA DE ACERTO E ERRO QUADRÁTICO MÉDIO

Para validar os resultados e avaliar a qualidade, desempenho e precisão do algoritmo de segmentação automática, foi realizado o cálculo da taxa de acerto, utilizando a Equação (8) (ANASTÁSIO, 2015) considerando o resultado ideal do volume gerado a partir das máscaras de referência em comparação ao volume da segmentação.

$$Taxa\ de\ Acerto = \left(\left(\frac{VtR - VtSA}{VtR}\right) * 100\right) - 100 \quad (8)$$

O resultado da taxa de acerto calculada em porcentagem, assim, quando a taxa for alta, próximo de 100, indica que a segmentação automática obteve resultados semelhantes à medida do volume real do fígado, e pode ser usada em diversas aplicações. Por outro lado, taxas de acertos baixas podem sinalizar que o algoritmo precisa de ajustes e revisão das imagens (ANASTÁSIO, 2015).

Analisando as taxas calculadas, foi obtido em 45% dos exames um acerto acima de 90%. Outro ponto importante foi que 90% dos volumes calculados pela segmentação apresentaram taxas de acerto acima de 80%. Em destaque com maior taxa de exatidão foi o exame 13, com 98,23% de acerto comparado ao volume de referência. A menor taxa foi o exame 4, que obteve apenas 48,54%. Investigando as imagens presentes nesse paciente, foi observado que 4,15% do banco de dados contém formatos de fígado atípicos, descrito na seção 4.1, para elevar a dificuldade do desafio (Tabela 8).

Tabela 8: Volumes calculados com as imagens modelos fornecidas na base e volume calculados pelo algoritmo de segmentação automática propostas e suas respectivas taxas de acerto para cada exame.

Exames	Volume referência (cm^3)	Volume Segmentação automática (cm^3)	Taxa de Acerto (%)
1	1.429,80	1.508,09	94,52
2	899,68	930,92	96,53
3	1.645,73	1.612,80	98
4	1.633,39	2.473,99	48,54
5	1.387,87	1.471,26	93,99
6	1.459,92	1.537,09	94,71
7	1.147,10	1.316,53	85,23
8	1.389,05	1.577,78	86,41
9	1.643,61	1.752,55	93,37
10	1.360,55	1.562,76	85,14
11	2.650,38	2.507,76	94,62
12	1.205,56	1.245,10	96,72

13	2.279,44	2.319,81	98,23
14	1.214,87	1.420,16	83,10
15	2.343,87	2.615,78	88,40
16	1.533,57	1.350,22	88,04
17	2.532,99	2.924,29	84,55
18	1.288,77	1.474,44	85,59
19	1.659,71	2.159,07	69,91
20	2.104,50	2.332,22	89,08
Média	**1.640,52**	**1.804,73**	**87,73%**

Fonte: Autora.

Além da taxa de acerto, foi realizado o cálculo do Erro Quadrático Médio (EQM), conforme Equação (9) (KAY,2023), onde envolve comparar o volume de fatia por fatia da segmentação automática com a máscara de referência. O EQM mede a diferença quadrada média entre os volumes das fatias nas duas segmentações, somando todas as diferenças quadradas e dividido pelo número total de fatias do exame.

$$EQM = \frac{1}{n}\sum_{i=1}^{n}(VFatSA_i - VFatR_i)^2 \quad (9)$$

Na Tabela 9 foi adicionado a taxa de acerto e o resultado do EQM, para obter uma avaliação mais abrangente do desempenho da segmentação. Visto que a taxa de acerto fornece uma medida de precisão geral do algoritmo, enquanto o EQM quantifica a diferença entre os valores segmentados e os reais. Por essa razão, ao unir as estatísticas uma visão mais detalhada da precisão global e a precisão em nível de cada *pixel* e fatia.

Quanto menor o valor do EQM, melhor o desempenho computacional do algoritmo, pois significa que possui pouca diferença entre o volume de cada *slice.* Logo, quanto mais próximo de zero for, menor a quantidade de erro na segmentação do fígado (ANASTÁSIO, 2015).

Tabela 9: Erro quadrático médio para cada exame.

Exames	Volume referência (cm³)	Volume Segmentação automática (cm³)	Taxa de Acerto (%)	EQM (cm³)
1	1.429,80	1.508,09	94,52	3,14
2	899,68	930,92	96,53	0,93
3	1.645,73	1.612,80	98	3,51
4	1.633,39	2.473,99	48,54	119,61
5	1.387,87	1.471,26	93,99	3,51
6	1.459,92	1.537,09	94,71	2,56
7	1.147,10	1.316,53	85,23	8,07
8	1.389,05	1.577,78	86,41	11,75

9	1.643,61	1.752,55	93,37	5,44
10	1.360,55	1.562,76	85,14	20,83
11	2.650,38	2.507,76	94,62	1,52
12	1.205,56	1.245,10	96,72	1,23
13	2.279,44	2.319,81	98,23	0,67
14	1.214,87	1.420,16	83,10	9,75
15	2.343,87	2.615,78	88,40	29,45
16	1.533,57	1.350,22	88,04	6,92
17	2.532,99	2.924,29	84,55	15,73
18	1.288,77	1.474,44	85,59	15,01
19	1.659,71	2.159,07	69,91	20,63
20	2.104,50	2.332,22	89,08	4,86

Fonte: Autora

Nos resultados o menor EQM está presente no exame 13, com valor próximo de zero resultando em 98,23% de taxa de acerto e EQM de 0,67. No exame 4 apresenta maior EQM, onde a técnica proposta não apresentou segmentação precisa do fígado.

5.2.3. COEFICIENTE DE SØRENSEN-DICE

Os resultados precisam ser analisados de outras perspectivas, para que clinicamente se tornem aceitáveis. Dessa forma, foi aplicado o coeficiente DICE, chamado de Índice de Similaridade de *SØrensen-Dice*, uma métrica amplamente utilizada no processamento de imagens médicas, que calcula a sobreposição entre a segmentação de referência e a segmentação automática, dada pela Equação (10) (KAVUR, 2020).

$$DICE = \frac{2|VRef \cap VSeg|}{|VRef| + |VSeg|} \quad (10)$$

Onde o coeficiente DICE considera tanto a região corretamente segmentada, como as áreas de falsos positivos e falsos negativos, quantificando a correspondência entre os dois volumes pelo tamanho médio de sua interseção.

DICE varia entre 0 e 1, onde 0 indica nenhuma sobreposição entre as regiões e 1 indica uma sobreposição perfeita. Quanto mais próximo o valor estiver de 1, maior será a similaridade entre o volume modelo de referência fornecido na base e o volume segmentado usando a proposta descrita no trabalho (MOGHBEL, 2018), (KAVUR, 2020).

Na Tabela 10 foi possível analisar o coeficiente DICE de cada exame, onde os resultados foram relevantes e próximos de 1, com destaque para o Exame de

número 11 que obteve 0,951, implicando alta taxa de similaridade entre o fígado da máscara e o fígado da segmentação automática.

Tabela 10: Volumes calculados com as imagens modelos fornecidas na base e volume calculados pelo algoritmo de segmentação automática com as técnicas propostas e seus respectivos coeficientes de DICE.

Exames	Volume referência (cm^3)	Volume Segmentação automática (cm^3)	DICE
1	1.429,80	1.508,09	0,915
2	899,68	930,92	0,9138
3	1.645,73	1.612,80	0,919
4	1.633,39	2.473,99	0,748
5	1.387,87	1.471,26	0,881
6	1.459,92	1.537,09	0,911
7	1.147,10	1.316,53	0,885
8	1.389,05	1.577,78	0,883
9	1.643,61	1.752,55	0,919
10	1.360,55	1.562,76	0,855
11	2.650,38	2.507,76	0,951
12	1.205,56	1.245,10	0,925
13	2.279,44	2.319,81	0,933
14	1.214,87	1.420,16	0,875
15	2.343,87	2.615,78	0,790
16	1.533,57	1.350,22	0,910
17	2.532,99	2.924,29	0,885
18	1.288,77	1.474,44	0,883
19	1.659,71	2.159,07	0,837
20	2.104,50	2.332,22	0,911

Fonte: Autora.

5.2.4. DIFERENÇA DE VOLUME ABSOLUTO RELATIVO

A métrica de *Relative Absolute Volume Difference* (RAVD) ou Diferença de Volume Absoluto Relativo se baseia na similaridade volumétrica entre o volume de referência e o volume da segmentação automática. Fornece uma medida relativa expressa em porcen*tag*em, calculada de acordo com a Equação (11) (KAVUR, 2020).

$$RAVD = \frac{||Vseg| - |VRef||}{|VRef|} \; x \; 100 \qquad (11)$$

Um RAVD próximo de zero indica uma concordância quase perfeita entre os volumes segmentados, enquanto um RAVD maior indica uma maior discrepância em volume (KAVUR, 2020), (MOGHBEL, 2018).

Uma particularidade importante no RAVD para as imagens de TC do fígado leva em consideração tanto as regiões de sobreposição, quanto às áreas que são removidas ou adicionadas na segmentação. Enquanto o coeficiente DICE mede a sobreposição espacial, o RAVD aborda diretamente a diferença em volume (KAVUR, 2020). Ao considerar tanto a sobreposição quanto a diferença em volume, obtemos uma visão mais completa do desempenho do algoritmo de segmentação.

Na Tabela 11, o exame 18 e 4 obteve um índice acima da amostra. No entanto, vale considerar que valores de RAVD muito baixos podem não ser alcançáveis em certos casos devido às limitações inerentes à técnica de segmentação utilizada ou à natureza variável da anatomia do fígado nas imagens.

Tabela 11: Volumes calculados com as imagens modelos da base e volume calculados pelo algoritmo proposto e as respectivas diferenças relativa do volume absoluto.

Exames	Volume referência (cm^3)	Volume Segmentação automática (cm^3)	RAVD (%)
1	1.429,80	1.508,09	5,48
2	899,68	930,92	3,47
3	1.645,73	1.612,80	2,00
4	1.633,39	2.473,99	51,46
5	1.387,87	1.471,26	6,01
6	1.459,92	1.537,09	5,29
7	1.147,10	1.316,53	14,77
8	1.389,05	1.577,78	13,59
9	1.643,61	1.752,55	6,63
10	1.360,55	1.562,76	14,86
11	2.650,38	2.507,76	5,38
12	1.205,56	1.245,10	3,28
13	2.279,44	2.319,81	1,77
14	1.214,87	1.420,16	16,90
15	2.343,87	2.615,78	11,60
16	1.533,57	1.350,22	11,96
17	2.532,99	2.924,29	15,45
18	1.288,77	1.474,44	14,41
19	1.659,71	2.159,07	30,09
20	2.104,50	2.332,22	10,92

Fonte: Autora.

Avaliando de forma geral todas as métricas, vale ressaltar que o Exame 13 apresentou melhor resultado em sua taxa de acerto, erro quadrático médio e diferença de volume absoluto relativo, apenas no DICE que o exame 11 apresentou 0,95 de similaridade. Esses resultados comparados aos algoritmos da competição CHAOS obteve o melhor desempenho com DICE (0,98 ± 0,00) e RAVD (%) de (1,32 ± 1,30).

6. CONCLUSÕES

As proporções do fígado, o formato e padrão de crescimento podem fornecer indícios acerca do volume do possível doador para TH. Portanto, tem sua relevância estabelecer se há aumento no tamanho do fígado, sua localização e calcular a volumetria para especificar os impactos correlacionados em caso de aprovação para ser transplantado. Além disso, a visualização 3D do fígado assistida por computador se torna igualmente indispensável para o planejamento de cirurgias, minimizando as incidências de complicações pós-operatórias.

A aplicação tridimensional na análise de imagens médicas aborda um diferencial na visualização, pois abrange mais estruturas anatômicas, eliminando a sobre posição dos tecidos e oferecendo uma perspectiva que ultrapassa as imagens 2D. Sendo assim, resulta em uma maior eficiência e segurança para o especialista durante intervenções com objetivo de melhorar os resultados do paciente.

Essa abordagem de segmentação proposta foi importante para a extração e análise quantitativa das características e propriedades específicas do fígado em cada exame, fornecendo uma base sólida para as conclusões e resultados apresentados neste trabalho. Dessa forma, o algoritmo criado obteve resultados promissores e destacou a região de interesse em termos de similaridade, visualização 3D, qualidade e precisão entre os resultados, onde mesmo com os desafios que a segmentação desse órgão apresenta, como variação anatômica, onde a base consiste com tamanhos incomuns e orientação fora do padrão obteve taxas de acerto média de 87,77% e máxima de até 98,23%.

Além dos desafios citados, outra variável complexa foi a heterogeneidade da intensidade que a tomografia apresenta entre os tecidos para distinguir o fígado de outras estruturas adjacentes, ou seja, intervalos de Hounsfield são semelhantes entre os órgãos próximos. Vale ressaltar, que os ruídos e artefatos que surgem no momento da realização do exame caracteriza a necessidade de um pré-processamento robusto.

A escolha da segmentação aplicando a técnica de *K-means*, ocorreu por intermédio de estudos fundamentais da própria base, anatomia e processamento digital de imagens, onde o método apresentou boa convergência. Importante notar

que como a área de imagens médicas possui grande dinâmica e variação, a qualidade da visualização 3D resultante depende proporcionalmente dos resultados obtidos na segmentação realizada. Dessa forma, a partir da avaliação foi aplicado a estratégia que resultou em uma extração das características adequada por meio de técnicas de aprendizado não supervisionado.

6.1 TRABALHOS FUTUROS

Para avançar na pesquisa, como perspectivas futuras, temos como proposta explorar abordagens avançadas para realizar ajustes finos, como uso de redes neurais, e o levantamento do tempo de processamento entre técnicas de segmentação diferentes, visto que o tempo configura um fator importante a ser considerado em qualquer sistema de auxílio assistido por computador para possíveis doadores de fígado. Além disso, para desenvolvimento futuro aplicar testes com exames com patologias hepáticas, para observar o comportamento do algoritmo proposto.

O refinamento contínuo do algoritmo, juntamente com a utilização de conjuntos de dados mais abrangentes em parceria com a colaboração entre pesquisadores e especialistas médicos também desempenharão um papel determinante na superação dessas adversidades e na melhoria da precisão da segmentação hepática em tomografias computadorizadas.

Diante disso, a segmentação sempre será considerada valiosa e necessária para aplicações clínicas, por exemplo, na prática clínica onde a identificação dos doadores mais apropriados para transplante de doação em vida e no planejamento pré-operatório demandam uma segmentação refinada do órgão hepático.

7. REFERÊNCIAS

A.E. Kavur, M. A. Selver, O. Dicle, M. Barış, N.S. Gezer. **CHAOS - Combined (CT-MR) Healthy Abdominal Organ Segmentation Challenge Data (Version v1.03) [Data set].** Apr. 2019. Zenodo. http://doi.org/10.5281/zenodo.3362844

A.E. Kavur, N.S. Gezer, M. Barış, S. Aslan, P.-H. Conze, *et al*. "**CHAOS Challenge - combined (CT-MR) Healthy Abdominal Organ Segmentation"**, Medical Image Analysis, Volume 69, 2021. doi: https://doi.org/10.1016/j.media.2020.101950

A.E. Kavur, N.S. Gezer, M. Barış, Y.Şahin, S. Özkan, B. Baydar, *et al*. **"Comparison of semi-automatic and deep learning-based automatic methods for liver segmentation in living liver transplant donors"**, Diagnostic and Interventional Radiology, vol. 26, pp. 11–21, jan. 2020. doi: https://doi.org/10.5152/dir.2019.19025

ACHARYA, Tinku; RAY, Ajoy K. **Image Processing**: Principles and Applications. New Jersey: John Wiley & Sons, 2005. 428 p.

Ahmad, Mubashir et al. "**A Lightweight Convolutional Neural Network Model for Liver Segmentation in Medical Diagnosis**." Computational intelligence and neuroscience vol. 2022 7954333. 30 Mar. 2022, doi:10.1155/2022/7954333

ANASTÁCIO, Rogério. **Segmentação e volumetria automática de fígado a partir de imagens tomográficas.** 2015. 152 f. Dissertação (Mestrado em Engenharias) - Universidade Federal de Uberlândia, Uberlândia, 2015. doi: https://doi.org/10.14393/ufu.di.2015.200.

ARAÚJO, José Denes Lima et al. Segmentação automática do fígado e lesões hepáticas em imagens de tomografia computadorizada usando redes neurais convolucionais. 2022.

ASSOCIAÇÃO BRASILEIRA DE TRANSPLANTE DE ÓRGÃOS (ABTO): Registro Brasileiro de Transplantes (RBT). [S. l.], 2022. Disponível em: https://site.abto.org.br/rbt/. Acesso em: 30 jun. 2023.

BASHIR, Mustafa R. **The LI-RADS® v2018 Manual**: CT/MRI Manual. [*S. l.*: *s. n.*], 2018.

BISHOP, Christopher M. **Pattern Recognition and Machine Learning**. Spring Street: New York, 2006. 738 p.

BITTENCOURT, Paulo Lisboa *et al*, (ed.). **Manual de cuidados intensivos em Hepatologia**. 1ª. ed. Barueri, SP: Manole Ltda, 2014. 532 p.

BRANT, William E.; HELMS, Clyde A. **Fundamentos de radiologia diagnóstico por imagem.** 4. ed. Porto Alegre: Artmed, 2014.

BUZUG, THORSTEN. **Computed Tomography**. 1. ed. Heidelberg: Springer Berlin, 2008.

CIERNIAK, ROBERT. **X-Ray Computed Tomography in Biomedical Engineering**. 1. ed. London: Springer, 2011. 319 p.

DICOMLIBRARY. DICOM *Tags*. [S.l.]: **DICOMLIBRARY**, [2013]. Disponível em: https://www.dicomlibrary.com/dicom/dicom-*Tags*/. Acesso em: 03 maio 2023.

FANG, Chihua et al. **Consensus recommendations of three-dimensional visualization for diagnosis and management of liver diseases. Hepatology International**, v. 14, p. 437-453, 2020.

FARIA, Diogo Alexandre Borges. **Segmentação, Reconstrução e Quantificação 3D de Estruturas em Imagens Médicas-Aplicação em Imagem Funcional e Metabólica**. 2013.

GONZALEZ, Rafael. **Processamento Digital de Imagens.** 3. ed. São Paulo: Pearson Education, 2009. 644 p.

GUYTON, Arthur C.; HALL, John E. **Tratado de Fisiologia Médica.** 12. ed. Rio de Janeiro: Elsevier, 2011.

Hruschka, E. R., Ebecken, N. F. F. **A Genetic algorithm for cluster analysis.** IEEE Transactions on Evolutionary Computation, 2001.

HEIMANN, Tobiaset al. "Comparison and Evaluation of Methods for Liver Segmentation From CT Datasets," in IEEE Transactions on Medical Imaging, vol. 28, no. 8, pp. 1251-1265, Aug. 2009, doi: 10.1109/TMI.2009.2013851.

INTERNATIONAL TRANSPLANT NURSES SOCIETY. [*S. l.*], 2011. Disponível em: https://www.itns.org/. Acesso em: 1 maio 2023.

K. Kaczor *et al.,* **"Comparison of image pre-processing methods in liver segmentation task,"** 2022 15th International Conference on Human System Interaction (HSI), Melbourne, Australia, 2022, pp. 1-5, doi: 10.1109/HSI55341.2022.9869505.

KAY, STEVEN. **Fundamentals of Statistical Signal Processing**: Practical Algorithm Development. 1. ed. Island: Pearson Education, 2013. 496 p. v. 3.

LEITE, Gabriel Henrique de Oliveira. **Comparação de técnicas 2D e 3D para segmentação do fígado em tomografia computadorizada.** 2017. 38 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Biomédica) – Universidade Federal de Uberlândia, Uberlândia, 2017.

LOPES, C.I.A. **Análise de algoritmos de filtragem para redução de ruído em imagens de tomografia computadorizada.** 2016. 57f. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) - Centro Federal de Educação Tecnológica de Minas Gerais, Belo Horizonte, 2016.

LYU, Fei et al. Weakly supervised liver tumor segmentation using couinaud segment annotation. IEEE Transactions on Medical Imaging, v. 41, n. 5, p. 1138-1149, 2021.

M. Islam, K. N. Khan and M. S. Khan, **"Evaluation of Preprocessing Techniques for U-Net Based Automated Liver Segmentation,"** 2021 International Conference on Artificial Intelligence (ICAI), Islamabad, Pakistan, 2021, pp. 187-192, doi: 10.1109/ICAI52203.2021.9445204.

MAHJOUB, Mohamed Ali et al. Automatic liver segmentation method in CT images. **arXiv preprint arXiv:1204.1634**, 2012.

MARTINI, FREDERIC H. **Anatomia Humana**. 6. ed. Porto Alegre: Artmed, 2009.

MATLAB. **Image Processing Toolbox.** 2022. Disponível em: https://www.mathworks.com/. Acesso em: 13 mai. 2023.

MENDES, Diana Sofia Xavier. **Segmentação 3D do Fígado em exames de TEP e TAC.** Coimbra, 2013. Tese de Mestrado.

MIES, S. **Transplante de fígado**. Rev Ass Med Brasil, São Paulo, 1998. doi: https://doi.org/10.1590/S0104-42301998000200011.

MOGHBEL, Mehrdad et al. Review of liver segmentation and computer assisted detection/diagnosis methods in computed tomography. **Artificial Intelligence Review**, v. 50, p. 497-537, 2018.

MOORE, Keith L; DALLEY, Arthur F.; AGUR, Anne M.R. **Anatomia Orientada para a Clínica.** 7. ed. Rio de Janeiro: Koogan, 2014.

MOURÃO, Arnaldo Prata *et al*. **Fundamentos de radiologia e imagem**. [*S. l.*]: Difusão Editora, 2009. 178-222 p.

MOREIRA, Fernando *et al*. **Guia de diagnóstico por imagem**. [*S. l.*]: Elsevier, 2017. 189 p.

NEMA. **The DICOM Standard.** 2023. Disponível em: <https://www.dicomstandard.org/current/ >. Acesso em: 02 mai. 2023.

RIBEIRO, Anabela de Magalhães. **Manual de tomografia computorizada do técnico de imagiologia médica**. 2007. Tese de Doutorado.

RIBEIRO, Marcus Antonio Rufino et al. Rede Social Gamer com modelagem do algoritmo K-means para indicação de novas amizades. 2022.

SANZ, Javier; FAROOQI, Kanwal Majeed; NIELSEN, James C.; SRIVASTAVA, Shubhika**. Image Acquisition for Creation of a 3D Model: CT, CMR, and Echocardiography. Rapid Prototyping In Cardiac Disease,** [s.l.], p. 21-30, 2017. Rapid Prototyping in Cardiac Disease. http://dx.doi.org/10.1007/978-3-319-53523-4_3.

SCHOLLEMBERG, Allan Jefferson. **Análise de sobrevida dos pacientes submetidos à transplante ortotópico de fígado no Hospital Universitário Professor Polydoro Ernani São Thiago no período de 2011 a 2018**. 2019. 52 p. Trabalho de Conclusão de Curso (Graduação em Medicina) - Universidade Federal de Santa Catarina, [*S. l.*], 2019.

SCURI, Antonio Escaño. Fundamentos da imagem digital. Rio de Janeiro, p. 16-18, 2002.

Selvalakshmi, V. M., & Nirmala Devi, S. (2017). **Segmentation and 3D visualization of liver, lesions and major blood vessels in abdomen CTA images. Biomedical Research-Tokyo,** 28, 7206-7212.

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.

THULUVATH, Paul J. et al. **Liver transplantation in patients with multiple organ failures: feasibility and outcomes**. Journal of hepatology, v. 69, n. 5, p. 1047-1056, 2018.

TORRES, Orlando. **Cirurgia de Fígado, Pâncreas e Vias Biliares**. Rio de Janeiro: Rubio Ltda, 2019. 724 p.

Y. Masutani, K. Uozumi, Masaaki Akahane, Kuni Ohtomo, **Liver CT image processing: A short introduction of the technical elements, European Journal of Radiology**, Volume 58, Issue 2, 2006, Pages 246-251, ISSN 0720-048X, https://doi.org/10.1016/j.ejrad.2005.11.044.

WEICKERT, J. **Applications of nonlinear diffusion in image processing and computer vision**. Comenianae: Acta Math, 2001.